

自适应多点最优最小熵反褶积在风电齿轮箱 轴承故障诊断中的应用

杨娜^{1,2}, 刘晔¹

(1. 西安交通大学 电气工程学院, 西安 710049; 2. 西京学院 计算机学院, 西安 710123)

摘要: 齿轮箱在风力发电机组传动系统中起着重要的作用, 因此齿轮箱故障诊断是风力发电机组健康管理中的一个关键问题; 考虑到齿轮箱振动信号的频谱复杂性, 多点最小最优熵反褶积方法是一种简单有效的齿轮箱故障诊断方法, 因为它不仅可以去除大量的背景噪声和振动干扰, 与此同时还能突出微弱的轴承故障脉冲信号; 但是该方法的性能在一定程度上取决于前置参数滤波器长度的选择, 不合适的滤波器参数值可能会导致过滤不足或过度过滤的后果; 为了解决这一问题, 提出了一种基于樽海鞘优化算法的自适应最优最小熵反褶积方法, 该方法可以自适应选择最优滤波器长度, 从而达到最优滤波效果; 最后, 利用包络解调方法对最优滤波信号进行包络分析得到包络谱, 从而揭示故障特征频率; 通过对某风力发电机实验台齿轮箱信号的仿真和实验分析, 说明了该方法的原理和有效性。

关键词: 风电机组; 齿轮箱; 故障诊断; 樽海鞘优化算法; 最小最优熵反褶积

Self-adaption Multipoint Optimal Minimum Entropy Deconvolution for Bearing Fault Diagnosis of a Wind Turbine Gearbox

YANG Na^{1,2}, LIU Ye¹

(1. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. School of Computing, Xijing University, Xi'an 710123, China)

Abstract: A gearbox plays a crucial role in the transmission system of wind turbines, gearbox fault diagnosis is a key issue in wind turbine health management. Aimed at the spectral complexity of gearbox vibration signals, a multipoint optimal minimum entropy deconvolution (MOMED) method is a simple and effective approach for gearbox fault diagnosis. This method not only eliminates the background noise and vibration interference, but also highlights the weak bearing pulse fault signals. However, the performance of this method depends on the appropriate selection of the pre parameter filtering length to a certain extent and inappropriate filtering parameters may cause the results of insufficient or excessive filtering. In order to address this issue, an adaptive optimal minimum entropy deconvolution (AMOMED) method based on the salp swarm algorithm (SSA) is proposed, which adaptively selects the optimal filter length and achieves the superior filtering effect. Finally, the envelope demodulation method is used to perform envelope analysis on the optimal filtered signal to obtain the envelope spectrum, thereby revealing the fault characteristic frequency. The principle and effectiveness of the proposed method are demonstrated through the simulation and experimental analysis of the gearbox signal on a certain wind turbine experimental platform.

Keywords: wind turbine; gearbox; fault diagnosis; SSA; MOMED

0 引言

在过去的十几年中, 风力机组的发电量增长了 400%。2018 年, 风电占全球当前可再生能源电力的很大一部分, 占总容量的 24%。这种增长是由公共投资、气候变化意识以及技术进步推动的。风力发电场对城市地区的干扰较小, 主要建立在风力更强、更稳定的区域, 同时采用了大型机组, 而大型机组反过来又可能产生更多的能量。然而, 风

电场的维护成本很高, 这就增加了对良好状态监测系统的需求, 以便进行预防性维护。根据相关数据显示, 在 20 年的运行寿命中, 风电场的维护成本可能达到陆地风电场总收入的 15%, 海上风电场总收入的 30%^[1]。如果有一个良好的状态监测系统, 可以进行预测性和预防性维护, 则可以大大降低成本^[2,3]。

齿轮箱结构紧凑, 传动能力大, 在风力发电机传动系

收稿日期: 2023-10-07; 修回日期: 2023-11-22。

基金项目: 西京学院科研基金资助项目(XJ220206)。

作者简介: 杨娜(1985-), 女, 硕士生。

通讯作者: 刘晔(-), 男, 博士生导师。

引用格式: 杨娜, 刘晔. 自适应多点最优最小熵反褶积在风电齿轮箱轴承故障诊断中的应用[J]. 计算机测量与控制, 2024, 32(11): 34

中得到广泛应用。然而,在风力发电场中,由于恶劣的工作条件,如重型载荷、阵风和粉尘腐蚀,因此齿轮箱易受到潜在的损坏。损坏的齿轮箱可能导致整个风力涡轮机的灾难性故障,从而造成极大的维修成本和生产损失。因此,齿轮箱的监测与诊断是风力发电机组的一个重要研究方向。作为风机齿轮箱中重要的传动件,轴承在传递过程中发挥着关键作用。然而,由于风机恶劣的工作环境,齿轮箱的轴承则很容易受到损伤。对早期齿轮箱轴承故障的检测就显得尤为重要,因为齿轮箱主轴传动轴承的质量将直接影响齿轮箱的其他零部件的回转精度、热特性和动态性能等关键性能指标。此外,齿轮箱的构造复杂,很多零部件间会产生耦合现象,因此提取出的轴承故障信号也具有复杂的频谱结构,包括了大量的背景噪声和齿轮啮合产生的振动干扰等,这都大大影响了齿轮箱轴承故障脉冲信号的分辨,因此对于齿轮箱轴承故障诊断的技术要求较高。

对于风电机组的齿轮箱故障诊断,学者们提出了几类有效的诊断方法。最早的诊断方法是采用统计检测指标用以衡量故障的严重程度。文献 [4] 采用了时域平均指标来揭示故障特征及其故障严重程度。文献 [5] 采用了循环平稳指标结合包络解调方法的策略来进行风电机组齿轮箱故障诊断。文献 [6] 采用了峭度指标来揭示风电机组齿轮箱磨损故障特征。这些工作大大丰富了风电机组齿轮箱故障监测的内容。然而,由于齿轮箱的特殊结构和动力学特性,导致其动态响应复杂,从而增加了振动信号的复杂度。因此,早期使用的统计检测指标在很多情况下无法满足复杂的频谱分析使得难以诊断齿轮箱故障^[7]。

意识到齿轮箱故障信号具有复杂的频谱结构后,一些学者将模态分解方法引入到风机齿轮箱故障诊断中。这是由于模态分解方法可以将一个具有复杂频谱结构的信号分解成多个只有单一分量的成分,即本征模函数 (IMF, intrinsic mode function)。分解后即可将只具有故障信息的分量单独拿出来进行包络分析,因此更易得到故障特征频率。文献 [8] 采用了经验模态分解方法与差分包络谱对齿轮箱进行故障特征提取。文献 [9] 采用了一种新颖的多辛几何模态分解方法来进行齿轮箱的复合故障诊断。文献 [10] 提出了一种基于奇异值分解的风电齿轮箱故障诊断方法。文献 [11] 则使用了一种称为变分模态分解的方法对风电齿轮箱振动信号进行干扰消除。文献 [12] 在变速的工况下采用了一种自适应啁啾模态分解方法对风电齿轮箱进行了故障分析与检测。由于模态分解方法的自身特性非常适合齿轮箱振动信号的分析,因此模态分解在该领域得到广泛应用。但是,模态分解方法仍有一些不足,如运算效率较低和分析流程繁琐等^[13]。

针对模态分解方法的不足,反褶积方法被引入了风电机组齿轮箱故障诊断当中。反褶积方法最早应用在地震脉冲信号的检测中,由于齿轮箱的轴承和齿轮故障脉冲信号与地震脉冲信号性质相似,因此该方法更加适合齿轮箱轴承或齿轮等故障诊断。反褶积方法不仅可以像模态分解方法一样去除噪声和振动干扰,还可以突显脉冲故障信号,

这是模态分解方法无法做到的。此外,它不需要像模态分解方法分解后再去选择合适的本征模函数,而是直接得到滤波信号,因此它避免了繁琐的分析过程^[14]。文献 [15] 为了解决行星齿轮微弱故障特征提取困难的问题,将最大相关峭度解卷积方法应用到行星齿轮箱微弱故障特征提取中。文献 [16] 提出了一种最小熵反褶积与奇异谱分解相结合的方法,用以解决在强噪声环境下齿轮箱复合故障信号微弱、故障特征难以提取等问题。文献 [17] 为了消除齿轮箱故障信号中的各种噪声和干扰,提出了一种新的自适应滤波方法——改进的最大相关峰度反褶积方法。

考虑到反褶积方法的优势,本文采用一种新颖的反褶积方法,多点最优最小熵反褶积 (MOMED, multipoint optimal minimum entropy deconvolution)^[18],应用到风机齿轮箱故障诊断中。MOMED 可将目标向量定义为需要反褶积的脉冲位置和权重,允许周期性脉冲序列反褶积目标,非常适合每次旋转的单个脉冲振动源的旋转机器故障的性质。此外, MOMED 有一个直接针对滤波器的非迭代最优解,因此滤波器的选择不需要迭代。目标向量可以同时求解,从而绘制出故障状态随分析周期变化的频谱。但是在使用 MOMED 方法之前,需要选择合适的滤波器长度,如果滤波器长度选择不合理,将会导致滤波效果较差。而人工选择滤波器长度不仅费时费力,还不能保证选择的合理性。为了解决这一不足,本文提出了一种基于樽海鞘优化算法的自适应多点最优最小熵反褶积方法 (AMOMED, adaptive multipoint optimal minimum entropy deconvolution)。樽海鞘优化算法 (SSA, salp swarm algorithm)^[19] 一种新的元启发式优化算法,它具有收敛速度快和更易得到全局最优解的优点,因此可以通过 SSA 自适应选择合适的正则化参数,有效提高参数选择的准确性,从而得到最优的轴承故障信号,为后续的包络分析提供了必要前提。

1 MOMED

MOMED 是利用滤波信号的多维 D 范数作为目标函数来识别具有多脉冲特征的冲击故障。这个滤波信号的多重 D 范数可定义为:

$$\text{MDN}(\vec{y}, \vec{t}) = \frac{1}{\|\vec{t}\|} \frac{t^T \vec{y}}{\|\vec{y}\|} \quad (1)$$

其中:目标向量 \vec{t} 表示一个常量向量,它决定了需要突出显示的目标脉冲分量的权重和位置。

通过将输入信号 \vec{x} 与反滤波系数 \vec{f} 进行卷积得到滤波信号 \vec{y} :

$$\vec{y} = \vec{x} * \vec{f} \quad (2)$$

MOMED 的最优反滤波器是通过最大化滤波信号的多维 D 范数来实现的,即:

$$(\vec{y}, \vec{t}) = \max_f \frac{t^T \vec{y}}{\|\vec{y}\|} \quad (3)$$

公式 (3) 的极值是通过对其求导并通过将其求导计算式等于 0 计算极值得到的。最优滤波器的 \vec{f} 输出解计算

如下:

$$\vec{f} = (\vec{X}_0 \vec{X}_0^T)^{-1} \vec{X}_0^T \vec{t} \quad (4)$$

其中:

$$\vec{X}_0 = \begin{bmatrix} x_L & x_{L+1} & x_{L+2} & \cdots & \cdots & x_N \\ x_{L-1} & x_L & x_{L+1} & \cdots & \cdots & x_{N-1} \\ x_{L-2} & x_{L-1} & x_L & \cdots & \cdots & x_{N-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_1 & x_2 & x_3 & \cdots & \cdots & x_{N-L+1} \end{bmatrix}_{L \text{ by } N-L+1} \quad (5)$$

在应用 MOMED 提取故障周期脉冲之前, 需要考虑周期脉冲的求解目标, 得到的求解目标为:

$$t_n = P_n(T) = \delta_{\text{round}(T)} + \delta_{\text{round}(2T)} + \cdots + \delta_{\text{round}(nT)} \quad (6)$$

其中: δ_n 表示样本 n 处的脉冲; T 表示故障周期; round 表示 MATLAB 程序中四舍五入取整, 意味着对于每个脉冲位置四舍五入到最近的整数位置。通过矩阵运算可以计算出最终滤波后的信号:

$$[\vec{y}_1, \vec{y}_2, \cdots, \vec{y}_N] = \vec{X}_0^T (\vec{X}_0 \vec{X}_0^T)^{-1} \vec{X}_0 [\vec{t}_1, \vec{t}_2, \cdots, \vec{t}_N] \quad (7)$$

式中,

$$\vec{X}_0 = \begin{bmatrix} x_L & x_{L+1} & x_{L+2} & \cdots & \cdots & x_N \\ x_{L-1} & x_L & x_{L+1} & \cdots & \cdots & x_{N-1} \\ x_{L-2} & x_{L-1} & x_L & \cdots & \cdots & x_{N-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_1 & x_2 & x_3 & \cdots & \cdots & x_{N-L+1} \end{bmatrix}_{L \text{ by } N-L+1}$$

2 基于 SSA 的自适应 MOMED

2.1 SSA

MOMED 能够实现较好的滤波效果, 并且能够突出周期性故障特征。然而, 在选择滤波器长度 L 时, 这对方法的性能有着重要影响, 但原方法未提供相应的选取准则。因此, 在本研究中采用 SSA 优化算法对 MOMED 的参数进行优化, 并获得最佳滤波器长度参数值, 以达到最佳的滤波结果。

樽海鞘优化算法 (SSA) 的主要理论来源为樽海鞘群的觅食行为。在整个樽海鞘群的捕食行为中, 通过对领导者 and 追随者进行数学建模来表达它们的快速导航和觅食, 从而实现运动。

樽海鞘领导者位置更新可用下面的数学模型表示:

$$x_j^1 = \begin{cases} F_j + c_1((ub_j - lb_j)c_2 + lb_j) & c_3 \geq 0 \\ F_j - c_1((ub_j - lb_j)c_2 + lb_j) & c_3 < 0 \end{cases} \quad (8)$$

其中: x_j^1 代表在第 j 维中领导者的位置; ub_j 和 lb_j 分别为第 j 维的上界和下界; F_j 代表食物源的位置 (第 j 维中); $c_2, c_3 \in [0, 1]$; c_1 最重要, 主要保证在探索与开发食物源时达到平衡, 其表达式为:

$$c_1 = 2e^{-4l/L^2} \quad (9)$$

其中: l 为当前迭代, L 表示最大迭代次数。

追随者的位置表达式如下所示:

$$x_j^i = \frac{1}{2}at^2 + v_0t \quad (10)$$

其中: $i \geq 2$ 表示第 i 个樽海鞘追随者在第 j 个维度中

的位置。该表达式为牛顿定律表达式, 因此 t 代表时间; v_0 代表初速度; a 代表加速度。为了简化表达, 设两次迭代之间的差值为 1, 则当 $v_0=0$ 时, 式子 (10) 可以变为:

$$x_j^i = \frac{1}{2}(x_j^i + x_j^{i-1}) \quad (11)$$

以上为樽海鞘链的群体觅食和导航行为的数学模型。

2.2 标函数

在该自适应 MOMED 方法中, 本文中采用了文献 [20] 中的包络谱峰度 (ESK, envelope spectrum kurtosis) 和负熵 (Ne, negentropy) 两种度量的乘积形式来构建目标函数, 该种度量函数不仅可以衡量脉冲特性还可衡量脉冲的循环特性^[21]。

因此, 目标函数可以定义为:

$$\arg \min_L \{1/(ESK \times Ne)\} \quad (12)$$

设置的寻优范围为 $L \in [500, 3500]$ 。其中:

$$ESK = \frac{(1/M) \sum_{i=1}^N |En(x)|^4}{[(1/M) \sum_{i=1}^N |En(x)|^2]^2} \quad (13)$$

式中, x 代表振动信号; M 为包络谱的时间段数; En 表示振动信号 x 的包络谱。

$$Ne = \frac{1}{N} \sum_{i=1}^N \left[\frac{x_i^2}{\frac{1}{N} \sum_{i=1}^N x_i} \ln \frac{x_i^2}{\frac{1}{N} \sum_{i=1}^N x_i} \right] \quad (14)$$

其中: N 为采样样本数; x_i 代表第 i 采样点。

2.3 自适应 MOMED

根据上述讨论, 提出了一种用于增强故障循环脉冲的自适应 MOMED 方法 (AMOMED)。通过建立目标函数, 利用 SSA 对滤波器长度 L 在不同的工况下进行自适应计算, 从而得到不同工况下的最优滤波信号。该本文所提方法的详细步骤如下。

- 1) 提取旋转机器的振动信号;
- 2) 根据式 (12) 确定滤波器长度 L 的范围;
- 3) 利用 SSA 计算最优的滤波器长度;
- 4) 获得最优滤波器长度 L ;
- 5) 使用 4) 得到的最优滤波器长度为 L 的 MOMED 过滤掉干扰分量, 从而识别出故障循环脉冲;
- 6) 得到最优过滤信号;
- 7) 对滤波后的信号进行包络分析得到故障特征频率。

3 实验验证

本次实验的目的主要验证本文所提方法的工程实用性, 并与原始的 MOMEDA 以及其他反褶积方法进行对比展现它的优越性。本小节采用的故障轴承数据采集自一组真实齿轮箱故障轴承。本次轴承故障分别存在于轴承内圈和轴承外圈, 即轴承内圈和轴承外圈故障。在实验验证中, 本研究使用了新南威尔士大学 (UNSW, university of new south wales) 提供的轴承故障数据。该齿轮箱故障模拟实验平台如图 1 所示。

对于采集信号, 输出轴的速度大约设置为 6 Hz (大约为每分钟 360 转)。信号的采样频率为 48 000 采样/秒

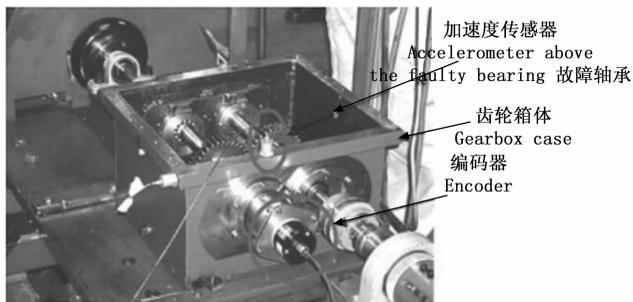


图 1 齿轮箱故障模拟实验平台

(48 kHz)。表 1 列出了轴承的几何尺寸信息。

表 1 轴承的几何尺寸

滚珠直径/mm	节径/mm	滚珠数量	接触角
7.12	38.5	12	0°

根据轴承的几何尺寸信息, 通过计算得到轴承的外圈故障特征频率 (BPFO, ball pass frequency outer) 为 29.34 Hz 和内圈故障特征频率 (BPFI, ball pass frequency inner) 为 42.66 Hz。需要注意的是, 由于加工误差和安装误差, 实际的轴承故障特征频率和理论计算出的故障特征频率会有一点偏差, 一般为 1%~2%。

3.1 轴承内圈故障诊断

首先, 对轴承内圈故障进行诊断。图 2 (a) 为轴承内圈故障信号波形图, 从波形图中可以看到, 轴承故障信号已经被齿轮啮合产生的干扰和背景噪声所掩盖, 已经无法分辨出故障脉冲序列。图 2 (b) 为该原始故障信号的包络谱, 可以看到, 在未进行前滤波处理的情况下, 包络分析无法直接提取出内圈故障特征频率。在包络谱中, 仅能观

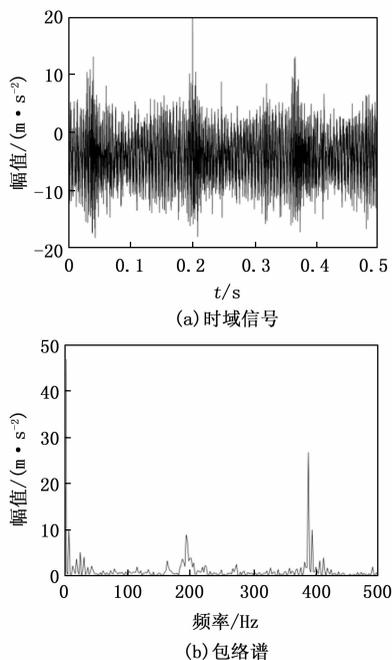


图 2 内圈故障信号波形图和包络谱

察到齿轮啮合产生的振动频率。

现使用本文所提的基于 SSA 的 MOMED 对该内圈故障信号进行滤波处理, 从而得到最优的滤波信号。根据所提方法步骤, 首先采用 SSA 对滤波长度 L 进行优化, 优化的过程如图 3 所示。可以看到, 当最佳适应值达到 0.612 5 时, 迭代过程趋于稳定。最终输出的最优滤波器长度为 $L=700$ 。

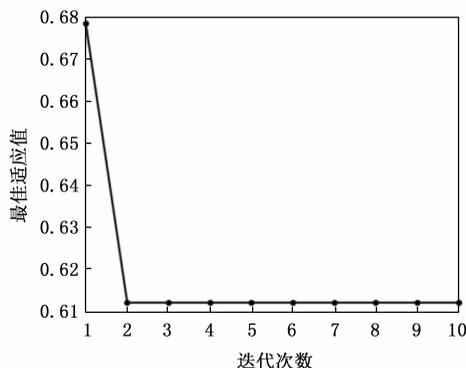


图 3 SSA 优化过程

将最优参数值 $L=1\ 800$ 代入 MOMED, 对内圈故障信号进行滤波处理, 得到的最优滤波信号如图 4 所示。

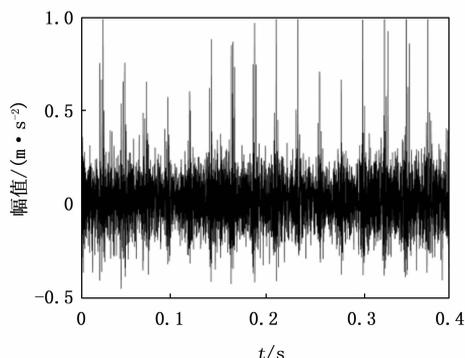


图 4 经 AMOMED 过滤的信号

从图 4 中可以看到, 本文所提出的 AMOMED 可以将内圈轴承故障信号中存在的强背景噪声和齿轮啮合产生的振动干扰去除, 并且同时可突显轴承故障脉冲序列。

最后对得到的最优过滤信号进行包络分析, 相应的包络谱如图 5 所示。可以看到, 经过 AMOMED 前处理后的信号包络谱可以明显地展示出内圈故障及其倍频, 说明 AMOMED 滤波效果显著, 为包络分析提供了可靠的前提。

3.2 外圈故障特征频率提取

外圈故障信号的时域波形如图 6 所示。从时域图 6 (a) 可以看到, 与内圈故障信号一样, 外圈故障信号也同样被背景噪声和齿轮啮合产生的振动频率所干扰, 因此无法从时域信号中分辨出轴承损伤产生的故障脉冲信号。同样地, 在相对应的包络谱中也无法显示出外圈故障特征频率及其倍频, 只有齿轮啮合产生的振动干扰频率。

现使用本文所提的 AMOMED 方法对原始信号进行预处理, 首先使用 SSA 对滤波器长度进行优化计算, 得到的优化收敛曲线如图 7 所示。可以观察到, 当最佳适应值达

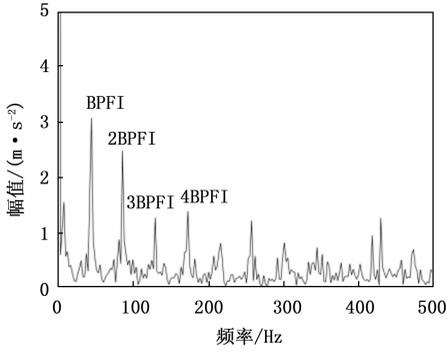
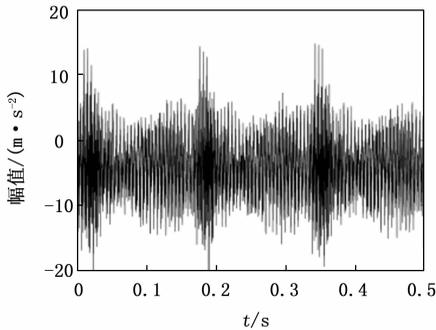
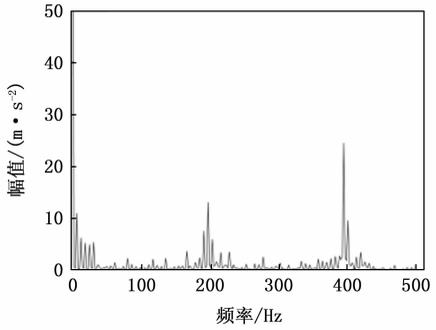


图 5 最优过滤信号的包络谱



(a) 时域信号



(b) 包络谱

图 6 外圈故障信号波形图及其相对应的包络谱

到 0.586 9 时, 曲线达到收敛状态, 得出的相对应的滤波器长度为 $L=2\ 200$ 。

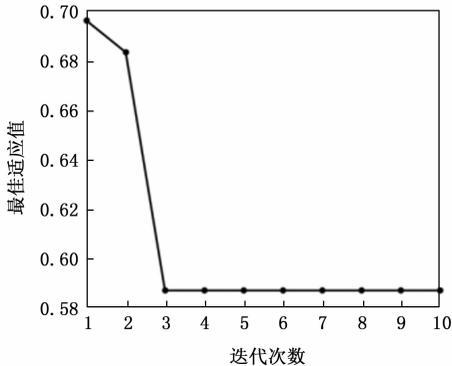


图 7 SSA 优化收敛曲线

使用该最优滤波器长度参数值代入 MOMED 方法中对

外圈故障信号进行滤波处理, 处理后的故障信号如图 8 所示。从图中可以看到, 经过 AMOMED 处理后的信号, 可以很好地突出故障脉冲信号, 并且将背景噪声和振动干扰也去除了。

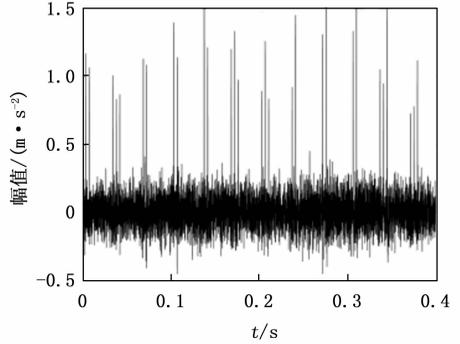


图 8 经 AMOMED 过滤的信号

然后对其进行包络分析, 得到的包络谱如图 9 所示, 可以从包络谱中明显地观察到外圈故障特征频率及其它的多个倍频, 说明了该方法的实用性。

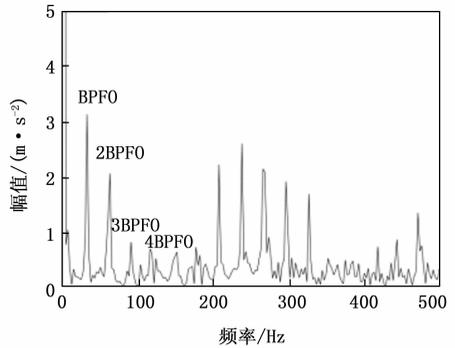


图 9 经 AMOMED 过滤信号的包络谱

3.3 与其他方法进行对比

为了体现本文所提 AMOMED 方法的优越性, 这里采用故障诊断中常用的最小熵反褶积方法和一种基于 Aotugram 的共振解调方法进行对比。

首先这里采用文献 [22] 中最小熵反褶积 (MED, minimum entropy deconvolution) 和包络一导数能量算子 (EDO, envelope-derivative operator) 的联合方法在轴承外圈故障诊断中进行对比。这个方法的原理和本文所提原理相似, 首先采用 MED 方法增强故障脉冲信号的强度, 然后使用 EDO 对过滤信号做出能量谱, 最终显示出故障特征频率。MED 也是反褶积方法的一种, 它的性能与 MOMED 相似, 不仅可以去除噪声和振动干扰, 还可以突出故障脉冲序列。而 EDO 实质上也是一种包络分析方法, 但相比于传统的包络分析方法, 它具有更好地噪声鲁棒性。

图 10 为 MED 滤波后的外圈故障波形图。从波形可以看到, 与 AMOMED 滤波的信号相似, MED 不仅去除了大量的背景噪声和振动干扰, 还突出了故障脉冲序列。但与图 8 中的滤波信号相比, 仍然可以发现, 该故障脉冲信号

的强度较弱, 显然没有 AMOMED 的过滤效果好。

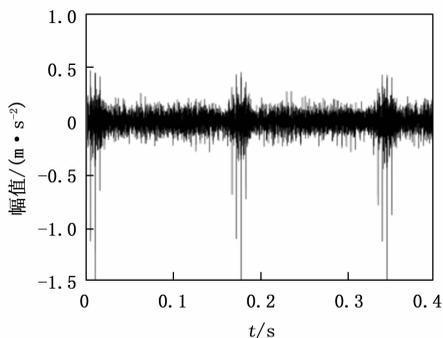


图 10 MED 滤波后的信号

然后使用 EDO 对滤波后的信号进行包络分析。得到的 EDO 能量谱如图 11 所示。

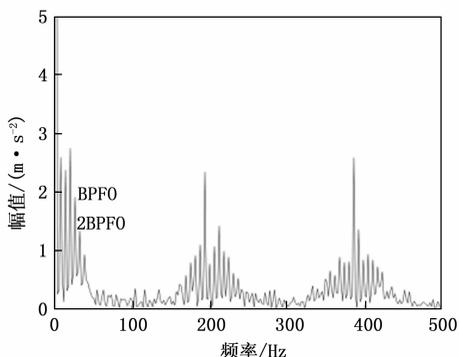


图 11 经 MED 过滤信号的 EDO 能量谱

从图 11 可以明显发现, 经过滤波后, EDO 虽然也可以从 MED 滤波后的信号中提取出外圈故障特征频率及其它的二倍频, 但是故障特征频率周围还密布着其他干扰频率, 并且幅值较高, 显然影响了故障特征频率及其倍频的分辨。此外, 能量谱中仅仅显示了故障特征频率的二倍频, 而其他倍频没有显示出来。而通过本文所提方法得到的包络谱可以明显地分辨出故障特征频率及其多个倍频, 并且也没有其他干扰频率出现在包络谱中, 这就大大提升了故障特征分辨能力。

接下来采用文献 [23] 中基于 Autogram 的共振解调方法与 AMOMEDA 在轴承内圈故障诊断中进行对比。该方法首先使用 Autogram 算法确定内圈故障信号共振频带的中心频率和带宽, 然后采用估计出的中心频率和带宽设计一个带通滤波器从而得到携带故障信息的共振信号, 然后对共振信号进行包络解调, 得到包络信号的包络谱, 根据包络谱中的故障特征来识别故障特征频率。

图 12 为 Autogram 图。从 Autogram 谱图中可以看到内圈故障信号的中心频率为 20 250 Hz 和带宽为 1 500 Hz。

随后采用这两个参数设计带通滤波器, 滤波后的结果如图 13 所示。可以看到, 通过该带通滤波器过滤后, 过滤后的信号可以显示出明显的脉冲特征。

最后对该滤波信号进行包络分析, 得到的包络谱如图

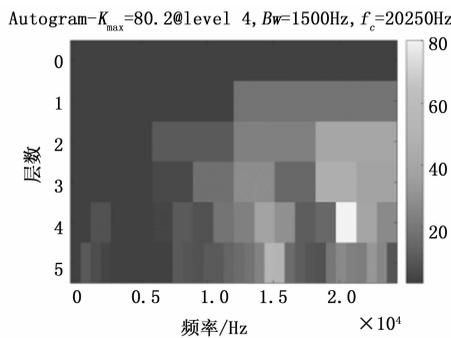


图 12 Autogram

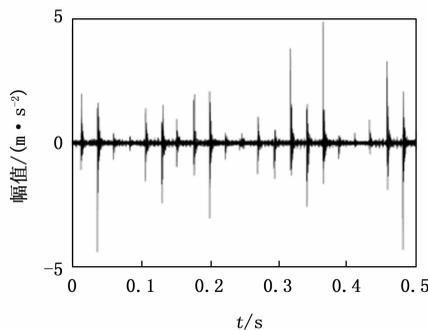


图 13 滤波信号

14 所示。可以看到, 包络谱中可以显示出内圈故障特征频率及其倍频。虽然基于 Autogram 的共振解调方法可以较好地提取出故障特征频率, 但是该方法的提取步骤较为繁琐, 首先需要估计出带宽和中心频率, 其次需要设计滤波器。除此之外, 如果该方法估计出的带宽和中心频率与理论值误差过大, 则会影响提取效果。

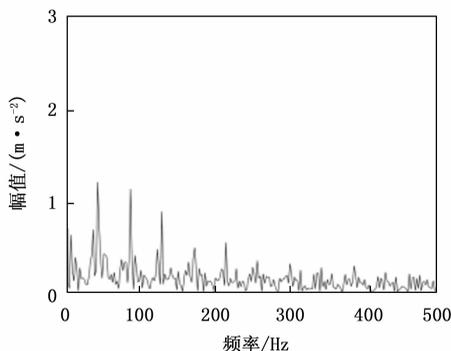


图 14 滤波信号的包络谱

通过对真实案例实验的结果可以发现, 经典的 MOMED 能够出去噪声和振动干扰, 并突出故障脉冲序列, 但是它的滤波效果对于滤波器长度的选择较为敏感下, 如果选择不当, 会导致后续的包络分析无法满足要求, 甚至无法提取出故障特征频率。相反, 所采用的基于 SSA 的自适应 MOMED 可以精确地选择合适的滤波器长度。虽然基于 MED 和 EDO 的联合方法也可以提取出多干扰下齿轮箱轴承故障特征频率, 但提取效果显然没有本文所提方法好。而与基于 Autogram 的共振解调方法相比, 虽然两种方法的

提取效果相差不大,但该种基于 SSA 的自适应 MOMED 方法显示了更直接的故障特征检测过程,避免了繁琐的流程,这一优势使其更易于在实践中应用。

4 结束语

本文提出了一种基于樽海鞘优化算法的自适应多点最优最小熵反褶积方法,用于在存在强背景噪声和振动干扰共存的情况下突出风机齿轮箱轴承故障循环脉冲,从而为下一步的包络分析提供可靠前提。利用新南威尔士大学提供的真实风机齿轮箱振动信号进一步验证了本文所提方法的有效性和优越性,并且与原始的多点最优最小熵反褶积方法和其他反褶积方法进行了对比,得出了以下结论:

1) 考虑到经典的多点最优最小熵反褶积方法的滤过效果取决于滤波器长度选择这一问题,本文采用了一种新颖的樽海鞘优化算法,并利用负熵建立了目标函数,利用所提出的目标函数优化滤波器长度 L 。这种自适应方法能够精确提取故障特征,避免了滤波器长度的盲目选择;

2) 与经典的多点最优最小熵反褶积方法和其他反褶积方法相比,本文所提出的方法在突出故障循环脉冲方面具有更高的性能,显示面对不断变化的工作条件时的可靠性;

但值得注意的是,将多点最优最小熵反褶积方法与樽海鞘优化算法相结合进行滤波器长度优化的计算量相对较大,尤其是数据量比较大时。这一不足可能会阻碍所提出方法的应用。在今后的工作中,我们将重视这个问题的解决。

参考文献:

[1] BERGSTR M L, KAUTSKY L, MALM T, et al. Effects of offshore wind farms on marine wildlife—a generalized impact assessment [J]. *Environmental Research Letters*, 2014, 9 (3): 2033–2053.

[2] 胡宇,唐小峰,文永康,等.基于贝叶斯网络的风力发电机故障诊断方法[J].*计算机测量与控制*,2021,29(4):51–58.

[3] 邹宇,李艳蓉,陈建炳,等.风力发电机偏航控制系统设计仿真技术研究[J].*计算机测量与控制*,2016,24(5):99–102.

[4] MCFADDEN P D. A technique for calculating the time domain averages of the vibration of the individual planet gears and the sun gear in an epicyclic gearbox [J]. *Journal of Sound and Vibration*, 1991, 144 (1): 163–172.

[5] ZIMROZ R, BARTELMUS W. Gearbox Condition Estimation Using Cyclo-Stationary Properties of Vibration Signal [J]. *Key Engineering Materials*, 2009: 413–414.

[6] BARSZCZ T, RANDALL R B. Application of spectral kurtosis for detection of a tooth crack in the planetary gear of a wind turbine [J]. *Mechanical Systems & Signal Processing*, 2009, 23 (4): 1352–1365.

[7] INALPOLAT M, KAHRAMAN A. A dynamic model to predict modulation sidebands of a planetary gear set having manufacturing errors [J]. *Journal of Sound and Vibration*, 2010, 329 (4): 371–393.

[8] 刘林密,曾庆松,崔伟成,等.基于经验模态分解与差分包络谱的齿轮故障诊断[J].*计算机测量与控制*,2021,29(3):54–58.

[9] ZHANG J, ZHANG Q, QIN X, et al. Gearbox compound fault diagnosis based on a combined MSGMD-MOMEDA method [J]. *Measurement Science and Technology*, 2022 (6): 33.

[10] 凌峰,杨宏强,邓艾东,等.基于SHSVD-AS的风电齿轮箱故障诊断[J].*太阳能学报*,2023,44(6):477–483.

[11] 许志华,潘庭龙.基于变分模态分解的风机齿轮箱振动信号降噪方法研究[J].*机电工程*,2021,38(1):4.

[12] WANG X, HE Y, WANG H, et al. A novel hybrid approach for damage identification of wind turbine bearing under variable speed condition [J]. *Mechanism and Machine Theory*, 2022, 169: 104629.

[13] XU Y, WANG Y, WANG L, et al. Bearing fault detection using an alternative analytic energy operator: A fast and non-filtering method [J]. *Measurement Science and Technology*, 2021, 32 (10): 105101.

[14] FAN J, QI Y, GAO X, et al. Compound fault diagnosis of rolling element bearings using multipoint sparsity-multipoint optimal minimum entropy deconvolution adjustment and adaptive resonance-based signal sparse decomposition [J]. *Journal of Vibration and Control*, 2020, 1–19.

[15] 刘峰,任丽佳.基于最大相关峭度解卷积行星齿轮箱微弱故障诊断[J].*噪声与振动控制*,2022,42(5):154–158.

[16] 周杰,王云艺,陈传海,等.基于改进MED-SSD的齿轮箱复合故障诊断方法[J].*吉林大学学报(工学版)*,2022,52(2):450–457.

[17] MIAO Y, ZHAO M, LIANG K, et al. Application of an improved MCKDA for fault detection of wind turbine gear based on encoder signal [J]. *Renewable Energy* 2020, 151: 192–203.

[18] MCDONALD GL and ZHAO Q. Multipoint optimal minimum entropy deconvolution and convolution fix; application to vibration fault detection [J]. *Mechanical Systems and Signal Processing*, 2017, 82: 461–477.

[19] CHEN Z Y, ZHANG D M, XIN Z Y. Multi-subpopulation based symbiosis and non-uniform gaussian mutation salp swarm algorithm [J]. *Acta Automatica Sinica*, 2022, 48 (5): 1307–1317.

[20] 杨娜,刘晔,徐元博,等.自适应稀疏贝叶斯滤波在轴承故障提取中的应用[J].*噪声与振动控制*,2023,43(3):132–138.

[21] HEBDA-SOBKOWICZ J, ZIMROZ R, PITERA M. Informative frequency band selection in the presence of non-Gaussian noise—a novel approach based on the conditional variance statistic with application to bearing fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2020, 145: 106971.

[22] 杨娜,刘晔,武昆.最优最小熵反褶积与包络-导数能量算子在轴承故障提取中的应用[J].*电子测量与仪器学报*,2020,34(4):134–141.

[23] 王慧滨,剡昌锋,孟佳东,等.融合Autogram的共振解调和1.5维谱的滚动轴承复合故障诊断方法[J].*振动工程学报*,2022,35(6):1541–1551.