

基于自适应粒子滤波与非线性维纳过程的风电轴承剩余寿命预测

宋得博¹ 祁文哲¹ 齐金平^{1,2}

(1. 兰州交通大学 机电工程学院, 兰州 730070)

(2. 兰州交通大学 研究院, 兰州 730070)

摘要:【目的】针对风电轴承在状态监测中存在的非线性干扰、非高斯噪声污染,以及退化过程的阶段性特征,构建了一种结合自适应粒子滤波与多阶段非线性维纳过程的模型。【方法】首先,将维纳过程引入粒子滤波的状态空间模型中,以增强模型的非线性表达能力;同时,采用自适应采样策略调整采样过程,有效避免粒子劣化,从而提高状态估计的准确性,并对轴承退化指标进行修正。其次,基于多阶段非线性维纳过程建立轴承的退化模型,考虑不同轴承个体之间的差异性,将漂移系数随机化;通过累积和算法确定轴承退化阶段的分段点,并采用最大似然估计算法对模型参数进行估计。最后,对试验台数据和风力发电机自由端轴承监测数据进行验证分析,并将所提出的方法预测的剩余寿命的结果与退化指标未滤波修正所得的进行对比。【结果】结果表明,所提出的方法具有更高的预测精度。

关键词: 风电机组; 滚动轴承; 自适应粒子滤波; 多阶段非线性维纳过程; 剩余寿命预测

中图分类号: TK83 **DOI:** 10.16579/j.issn.1001.9669.2026.05.001

0 引言

滚动轴承作为风电机组的核心部件,承担着支撑旋转部件(如风轮、主轴、发电机转子等)并确保其顺畅运转的重任,滚动轴承的健康状态直接关乎机组运行效率与稳定性^[1-2]。然而,风电机组常工作于复杂工况及恶劣环境中,会加剧机组中轴承的腐蚀与磨损,甚至直接造成轴承损坏,导致停机维修,增加了运行成本^[3-4]。因此,对滚动轴承进行实时状态监测与寿命预测,对于风电机组的健康监控以及制定有效的维护策略至关重要。

目前,国内外学者针对滚动轴承的剩余使用寿命预测方法进行了广泛研究,主要包括失效机制模型、基于数据驱动的方法及数模联动方法^[5]。其中,失效机制模型无法同时考虑失效机制、环境和多失效模式竞争等因素,模型构建的难度较大^[6]。而基于数据驱动的方法不依赖于特定的失效机制,适用于多种轴承类型和轴承工作环境复杂的情况,且该方法能够捕捉到轴承性能退化的细微变化,从而实现高精度的预测。基于数据驱动的方法主要涵盖基于机器学习的方法和基于不确定性的方法两大类。其中,基于不确定性的方法包括统计回归方法、模糊理论、灰色理论

和随机过程等^[7-9]。使用随机过程建立系统的退化模型进行寿命预测,不仅能输出各监测时刻点轴承剩余寿命的预测值,还能提供预测结果的概率分布信息。

随机过程中的维纳过程在任何有限时间上的变化服从正态分布,这一特性使得其增量分布易于分析和处理,从而简化了寿命预测的计算过程,广泛应用于装备的寿命预测领域。金晓航等^[10]基于二元维纳过程模型,预测了轴承的剩余寿命。丁显等^[11]²⁴⁸⁻²⁵⁰融合维纳过程和粒子滤波算法,预测了风电轴承的剩余寿命。GUO等^[12]利用自适应模态分解和核主成分分析方法构建了一种新的轴承健康指标,结合非线性维纳过程进行了轴承的剩余寿命预测。WU等^[13]提出一种新的状态空间模型,考虑了系统多退化指标之间的相关性,推导了多指标系统在多故障模式下的剩余寿命。然而,当前研究均直接对装备的各退化指标进行分析从而得到其剩余寿命,这些退化指标表征装备不同属性的退化状态,这就要求所建立的退化指标能够精确描绘当前时刻装备的健康状态^[14]。粒子滤波算法在处理非线性、非高斯动态系统方面表现出色,因此广泛应用于装备健康状态估计和剩余使用寿命预测等领域^[15]。HONG等^[16]从锂离子电池放电曲线

收稿日期: 2024-10-11 修回日期: 2024-11-28

基金项目: 甘肃省重点研发计划项目(23YFGA0050)

作者简介: 宋得博,男,2001年生,甘肃庆阳人,硕士;主要研究方向为风电机组关键部件剩余寿命预测; E-mail:2052866579@qq.com。

祁文哲(通信作者),男,1966年生,甘肃临夏人,教授,硕士研究生导师;主要研究方向为机电设备控制与检测技术、工业检测技术与系统设计、机车车辆状态检测及故障诊断等; E-mail:qiwz@mail.lzjtu.cn。

引用格式: 宋得博,祁文哲,齐金平. 基于自适应粒子滤波与非线性维纳过程的风电轴承剩余寿命预测[J]. 机械强度,2026,48(5): 1-8.

SONG Debo, QI Wenzhe, QI Jinping. Residual life prediction of wind turbine bearings based on adaptive particle filtering and nonlinear Wiener process[J]. Journal of Mechanical Strength, 2026, 48(5): 1-8.



免费获取

中提取特征电压作为健康指标,建立了“特征电压-容量-循环时间”模型,采用改进的粒子滤波算法实时估计特征电压,实现了锂离子电池的健康状态估计和寿命预测。张新雨等^[17]设计一种自适应重采样策略来调整粒子滤波,增加粒子多样化,提高了模型状态估计的精度。风力发电机轴承在状态监测过程中受到多种非线性因素(环境因素、载荷因素、材料和几何非线性、接触非线性等)及非高斯噪声的干扰,同时,由于轴承内部零件在不同服役时间下的磨损和裂纹扩展情况不同,轴承退化呈现阶段性。因此,需要充分考虑退化指标对装备健康状态表征的准确性,以及轴承的阶段性退化特征对其寿命预测的影响。

针对上述问题,本文构建一种自适应粒子滤波与多阶段非线性维纳过程模型。一方面,将维纳过程引入粒子滤波状态空间模型,增强模型的非线性表达能力,并使用自适应采样策略对模型进行调优,避免粒子劣化,提高模型状态估计的准确性;另一方面,构建多阶段非线性维纳过程来建立轴承退化模型,并利用累积和(Cumulative Sum, CUSUM)算法进行变点检测,结合最大似然估计(Maximum Likelihood Estimation, MLE)算法对模型参数进行估计。最终,基于试验台滚动轴承的全寿命数据和风力发电机自由端轴承监测数据,以验证本文所提模型的有效性和实用性。

1 自适应粒子滤波

1.1 维纳过程

轴承性能退化是一个典型的维纳过程。维纳过程是一种独立增量过程,可以描述系统的实际退化过程,其表达式为

$$x(t+1) = x(t) + \eta + \sigma B(t) \quad (1)$$

式中, $x(t)$ 为 t 时刻的健康状态; η 为漂移参数; σ 为扩散系数; $B(t)$ 为标准布朗运动, $B \sim N(0, 1)$ 。

1.2 粒子滤波

粒子滤波是一种基于蒙特卡洛方法的非线性、非高斯状态估计技术,它利用1组在空间中传播的随机样本来近似表示概率密度函数,进而获得样本的最小方差估计^[18]。

在粒子滤波中,首先将维纳过程引入到粒子滤波的状态模型中,得到状态方程和观测方程。由于粒子滤波是在离散的时间点上进行操作,而维纳过程是一种连续时间的随机过程,因此需要通过欧拉离散化,得到离散的维纳过程,进而分别得到状态方程和观测方程,即

$$\begin{cases} \eta_{t+1} = \eta_t + v_t \\ x_{t+1} = x_t + \eta_t + \varepsilon_t B(t) \end{cases} \quad (2)$$

$$y_t = x_t + w_t \quad (3)$$

式中, x_t, y_t, η_t 分别为 t 时刻估计的健康状态、观测状态和漂移参数; v_t 为 t 时刻的过程噪声, $v_t \sim N(0, \varepsilon_v^2)$, v_t 的标准差 ε_v 可通过计算状态增量 Δx 的方差来估计; w_t 为观测噪声, $w_t \sim N(0, \varepsilon_w^2)$, w_t 的标准差 ε_w 可以通过监测设备设计参数获得。根据维纳过程的性质,状态增量 Δx 服从高斯分布,即 $\Delta x \sim N(0, \sigma \Delta t)$, Δt 为时间增量。

粒子滤波的核心思想是通过随机抽取的一系列样本(粒子)来近似表示状态的后验概率分布。这些粒子携带权重,表示其对应状态发生的可能性。通过蒙特卡洛方法,利用这些带权重的粒子来计算期望,从而近似得到后验概率 $p(x_k|y_{1:k})$ 的估计值^{[19]689-709},即

$$p(x_k|y_{1:k}) \approx \sum_{i=1}^{N_s} z_k^{(i)} \delta(x_k - x_k^{(i)}), \quad i=1, 2, \dots, N_s \quad (4)$$

式中, k 为离散监测时刻; x_k 为 k 时刻的健康状态; $x_k^{(i)}$ 为 k 时刻第 i 个粒子的观测状态; $\delta(x_k - x_k^{(i)})$ 为观测误差; $z_k^{(i)}$ 为 k 时刻第 i 个粒子的权重; N_s 为粒子个数; $y_{1:k}$ 为从时刻1到时刻 k 的观测序列。

实际应用中,后验概率通常是未知的,因此,常选用先验密度 $p(x_k|x_{k-1})$ 来指导粒子的采样。为了解决粒子滤波中的重复计算权重值问题,采用序贯重要性采样方法,将样本写成序列形式,通过递归更新的方法来计算每个粒子对应的权重值。最后得到简化的粒子采样公式和权重迭代公式,分别为

$$x_k^{(i)} \sim p[x_k|x_{k-1}^{(i)}] \quad (5)$$

$$z_k^{(i)} \propto z_{k-1}^{(i)} p[y_k|x_k^{(i)}] \quad (6)$$

式中, y_k 为 k 时刻的观测状态。

为避免粒子滤波在迭代运算时出现粒子退化现象,采用重采样方法复制并保留大权重粒子,淘汰小权重粒子,从而抑制粒子退化。重采样后新粒子独立分布,因此需要更新权重,表示为

$$z_k^{(i)} = z_k^{(i)} / \sum_{i=1}^{N_s} z_k^{(i)} \quad (7)$$

粒子重采样后的状态估计为

$$\hat{x}_k \approx \sum_{i=1}^{N_s} z_k^{(i)} x_k^{(i)} \quad (8)$$

式中, $\hat{x}_k$ 为 k 时刻的预测状态。

1.3 自适应采样策略

布朗运动存在的较大随机性(如独立增量、马尔可夫性质、连续时间等)加剧了粒子滤波在粒子采样过程中的粒子劣化现象,因此使用自适应采样策略进行调整,以提高状态估计的准确性。同时为了适应轴承的阶段性退化特征,在预测观测值阶段使用双指数

函数进行分段拟合,即

$$\hat{y}_k = \begin{cases} y_k, & 0 < k \leq \tau \\ f(\hat{\theta}_k, k), & k > \tau \end{cases} \quad (9)$$

其中,

$$\hat{\theta}_k = \arg \max_{\theta} p(\theta | \hat{y}_{\tau:k-1}) \quad (10)$$

式中, $\hat{y}_k$ 为观测预测值; $f(\cdot)$ 为非线性函数; θ_k 为非线性函数参数, $\hat{\theta}_k$ 为其最大似然估计值; $\hat{y}_{\tau:k-1}$ 为观测估计值; τ 为轴承退化过程中的时间变点。

在自适应采样策略中,首先,根据系统过程噪声和测量噪声的统计特性,初始化1组粒子。在每个时间步长内通过状态转移方程对粒子进行更新,并计算每个粒子的权重。然后,利用粒子权重的有效样本大小 S_{ESS} 作为评估指标,判断当前粒子集的多样性,即

$$S_{\text{ESS}} = 1 / \sum_{i=1}^{N_s} [z_k^{(i)}]^2 \quad (11)$$

在自适应调整粒子数量时,若 S_{ESS} 低于预设阈值 S_{ESSD} ,则表明粒子劣化严重,此时通过增加粒子数量以增强粒子集的代表性;反之,则适当减少粒子数量以提高计算效率。粒子数量 N_s 的调整采用线性增减策略,其中增减比例由自适应调整系数 α 控制,即

$$N_s = \begin{cases} \min([N_s(1+\alpha)], N_{\max}), & S_{\text{ESS}} < S_{\text{ESSD}} \\ \max([N_s(1-\alpha)], N_{\min}), & S_{\text{ESS}} \geq S_{\text{ESSD}} \end{cases} \quad (12)$$

式中, $N_{\max}$ 、 $N_{\min}$ 分别为粒子数的上限值、下限值。

最后,通过重采样步骤消除权重较小的粒子,并基于更新后的粒子集进行状态估计。在粒子滤波状态估计中采用自适应采样策略,其目的是依据系统状态动态调整采样,防止粒子劣化,增加粒子多样性以更好地覆盖状态空间,提高估计精度,适应非线性、非高斯系统及其动态变化,提升算法效率和对复杂系统的适应性。

2 轴承寿命预测

2.1 多阶段非线性维纳过程模型构建

针对轴承退化呈现的阶段规律,本文在单阶段维纳过程模型的基础上推导多阶段非线性维纳过程^{[19]689-709}。多阶段非线性维纳过程模型为

$$X(t) = \begin{cases} x_0 + \mu_1 t^a + \sigma_1 B(t), & 0 < t \leq \tau \\ x_\tau + \mu_2 (t - \tau)^b + \sigma_2 B(t - \tau), & t > \tau \end{cases} \quad (13)$$

式中, $X(\cdot)$ 为非线性情况下估计的健康状态; x_0 为初始状态; x_τ 为变点退化状态; μ_1 、 μ_2 分别为第1、第2阶段的漂移系数; σ_1 、 σ_2 分别为第1、第2阶段的扩散系数;

$$f_L(l_i | t > \tau) = \frac{D - x_i - \mu_2 [(t + l_i - \tau)^b - (t - \tau)^b - bl_i(t + l_i - \tau)^{b-1}]}{\sqrt{2\pi l_i^3 \sigma_2^2}} \cdot \exp\left(-\frac{\{D - x_i - \mu_2 [(t + l_i - \tau)^b - (t - \tau)^b - bl_i(t + l_i - \tau)^{b-1}]\}^2}{2l_i \sigma_2^2}\right) \quad (18)$$

a 、 b 为非线性参数。在实际情况中,轴承的生产、使用、运行环境等方面存在差异性,因此考虑单位之间的可变性,令 $\mu_1 \sim N(\eta_1, \sigma_{\mu_1}^2)$, $\mu_2 \sim N(\eta_2, \sigma_{\mu_2}^2)$, 其中, η_1 、 η_2 为第1、第2阶段中退化速率的平均水平(群体平均退化趋势); $\sigma_{\mu_1}^2$ 、 $\sigma_{\mu_2}^2$ 为第1、第2阶段不同个体之间退化速率的离散程度。

2.2 寿命预测计算

当轴承的退化性能指标首次达到失效阈值 D ($D > 0$) 时,认定轴承失效。因此轴承的剩余寿命 L_i 可以定义为

$$L_i = \inf \{l_i : X(l_i + t) \geq D | X(t) \geq D\} \quad (14)$$

式中, l_i 为 t 时刻的预测剩余寿命。

由于轴承退化时,各个退化阶段都符合非线性维纳过程,根据非线性维纳过程的性质,轴承的剩余寿命 L_i 服从逆高斯分布。基于非线性维纳过程模型,当轴承的退化性能指标首次达到失效阈值 D 时,其跨越恒定边界 D 的概率密度函数表达式为

$$f_L(t) = \frac{1}{\sqrt{2\pi t}} \left[\frac{S(t)}{t} + \frac{\eta \Lambda(t)}{\sigma} \right] \exp\left[-\frac{S^2(t)}{2t}\right] \quad (15)$$

式中, $\Lambda(t)$ 为非线性函数,可根据退化规律进行选择; $S(t)$ 的表达式为

$$S(t) = \frac{D - \mu \Lambda(t)}{\sigma} \quad (16)$$

式中, μ 为漂移系数。

基于式(15)和式(16),可以得到轴承的剩余寿命概率密度函数的2种情况。

情况1:当轴承运行时间 t 在变点之前,即 $0 < t \leq \tau$,此阶段仍可能存在2种失效模式。这2种失效模式所对应的轴承剩余寿命概率密度函数分别为

$$f_L(l_i | t \leq \tau) = \begin{cases} \frac{D - x_i - \mu_1 [(t + l_i)^a - t^a - al_i(t + l_i)^{a-1}]}{\sqrt{2\pi l_i^3 \sigma_1^2}} \cdot \exp\left(-\frac{\{D - x_i - \mu_1 [(t + l_i)^a - t^a - al_i(t + l_i)^{a-1}]\}^2}{2l_i \sigma_1^2}\right), & t + l_i \leq \tau \\ \frac{D - x_\tau - \mu_2 [(t + l_i - \tau)^b - bl_i(t + l_i - \tau)^{b-1}]}{\sqrt{2\pi l_i^3 \sigma_2^2}} \cdot \exp\left(-\frac{[D - x_\tau - \mu_2 [(t + l_i - \tau)^b - bl_i(t + l_i - \tau)^{b-1}]]^2}{2l_i \sigma_2^2}\right), & t + l_i > \tau \end{cases} \quad (17)$$

式中, x_τ 为 τ 时刻的退化状态。

情况2:轴承的运行时间 t 在变点之后,即 $t > \tau$,此时剩余寿命概率密度函数为

3 轴承退化过程变点分析及参数估计

3.1 基于CUSUM算法的变点分析

CUSUM算法通过累积数据差异,能实时敏感捕捉微小变化,提高小幅度变化的检测能力。同时,算法参数可调,适应性强。这些优点使CUSUM算法成为变点检测领域的有效工具。由多阶段非线性维纳过程的定义可知,轴承在不同退化阶段具有不同的退化速率,从而反映不同的扩散系数和漂移系数。本文采用CUSUM算法对轴承退化过程中的变点进行分析,其通过计算数据序列的累积和来监测数据的偏离程度,并在累积和的单调性发生变化时触发事件,从而对退化过程中的时间变点(分段点)进行识别^[20],识别过程如下:

1) 计算轴承退化数据的期望,为

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (19)$$

式中, N 为样本容量; x_i 为轴承的第 i 个退化状态; $i = 1, 2, 3, \dots, N$ 。

2) 计算数据序列 $(x_i - \bar{x})$ 的累积和,令 $S_0 = 0, S_1 = S_0 + (x_1 - \bar{x}), S_2 = S_1 + (x_2 - \bar{x}), \dots, S_i = S_{i-1} + (x_i - \bar{x}), i = 1, 2, \dots, N$ 。

3) 根据 S_i 的单调性来识别时间变点,使 S_i 的单调性发生变化的点即为时间变点。

3.2 基于MLE算法的参数估计

基于多阶段非线性维纳过程的轴承退化模型建立完成后,在进行寿命预测时,需要使用历史数据对模型中的未知参数 $\theta = (\mu_1, \sigma_{\mu_1}^2, \sigma_1, \mu_2, \sigma_{\mu_2}^2, \sigma_2)$ 进行估计。轴承不同时刻的退化状态服从正态分布,时间变点前、后 2 个阶段的退化状态满足的分布分别为

$$\begin{cases} X_1(t) = [x_1, x_2, \dots, x_{n_1}]^T \sim N(\mu_1 t^a, \sigma_{\mu_1}^2 t^{2a} + \sigma_1^2 t) \\ X_2(t - \tau) = [x_{n_1+1} - x_{n_1}, x_{n_1+2} - x_{n_1}, \dots, x_{n_1+n_2} - x_{n_1}] \sim N[\mu_2(t - \tau)^b, \sigma_{\mu_2}^2(t - \tau)^{2b} + \sigma_2^2(t - \tau)] \end{cases}$$

整理为

$$X_1(t) = [x_1, x_2, \dots, x_{n_1}]^T \sim N(\mu_1 T_1, \Sigma_1) \quad (20)$$

$$X_2(t - \tau) = [x_{n_1+1} - x_{n_1}, x_{n_1+2} - x_{n_1}, \dots, x_{n_1+n_2} - x_{n_1}]^T \sim N(\mu_2 T_2, \Sigma_2) \quad (21)$$

其中, $T_1 = [\Lambda_1(t_1), \Lambda_1(t_2), \dots, \Lambda_1(t_{n_1})]^T$; $T_2 = [\Lambda_2(t_{n_1+1} - t_{n_1}), \Lambda_2(t_{n_1+2} - t_{n_1}), \dots, \Lambda_2(t_{n_1+n_2} - t_{n_1})]^T$; $\Sigma_1 = \sigma_{\mu_1}^2 T_1^T T_1 + \sigma_1^2 Q_1$; $\Sigma_2 = \sigma_{\mu_2}^2 T_2^T T_2 + \sigma_2^2 Q_2$ 。

式中, Q_1, Q_2 分别为时间变点前、后 2 个阶段的样本容量。

根据以上条件,结合剩余寿命的概率密度函数,可得多阶段非线性维纳过程模型的对数似然函数为

$$\begin{aligned} \ln L(\theta|X) = & -\frac{n_1}{2} \ln(2\pi) - \frac{1}{2} \ln|\Sigma_1| - \frac{1}{2} (X_1 - \mu_1 T_1)^T (\Sigma_1)^{-1} (X_1 - \mu_1 T_1) - \\ & -\frac{n_2}{2} \ln(2\pi) - \frac{1}{2} \ln|\Sigma_2| - \\ & -\frac{1}{2} (X_2 - X_{n_1} - \mu_2 T_2)^T (\Sigma_2)^{-1} (X_2 - X_{n_1} - \mu_2 T_2) \end{aligned} \quad (22)$$

式中, n_1 为第 1 阶段的样本数; n_2 为第 2 阶段的样本数;

$$X_{n_1} = [x_{n_1}, x_{n_1}, \dots, x_{n_1}]^T_{1 \times n_2}; X = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix}。$$

接下来将式(22)的对数似然函数分别对 $\mu_1, \sigma_{\mu_1}^2, \mu_2, \sigma_{\mu_2}^2$ 求偏导,并将所得到的导函数的值取 0,从而得到 $\mu_1, \sigma_{\mu_1}^2, \mu_2, \sigma_{\mu_2}^2$ 的估计值,分别表示为

$$\begin{aligned} \mu_1 = & [T_1^T (\frac{\sigma_{\mu_1}^2}{\sigma_1^2} T_1^T T_1 + Q_1)^{-1} X_1] / \\ & [T_1^T (\frac{\sigma_{\mu_1}^2}{\sigma_1^2} T_1^T T_1 + Q_1)^{-1} T_1] \end{aligned} \quad (23)$$

$$\begin{aligned} \sigma_{\mu_1}^2 = & [(X_1 - \mu_1 T_1)^T (\frac{\sigma_{\mu_1}^2}{\sigma_1^2} T_1^T T_1 + \\ & Q_1)^{-1} (X_1 - \mu_1 T_1)] / n_1 \end{aligned} \quad (24)$$


$$\begin{aligned} \mu_2 = & [T_2^T (\frac{\sigma_{\mu_2}^2}{\sigma_2^2} T_2^T T_2 + Q_2)^{-1} (X_2 - X_{n_1})] / \\ & [T_2^T (\frac{\sigma_{\mu_2}^2}{\sigma_2^2} T_2^T T_2 + Q_2)^{-1} T_2] \end{aligned} \quad (25)$$

$$\begin{aligned} \sigma_{\mu_2}^2 = & [(X_2 - X_{n_1} - \mu_2 T_2)^T (\frac{\sigma_{\mu_2}^2}{\sigma_2^2} T_2^T T_2 + \\ & Q_2)^{-1} (X_2 - X_{n_1} - \mu_2 T_2)] / n_2 \end{aligned} \quad (26)$$


最后,将上述得到的参数的估计值代入式(22)中,寻找 σ_1, σ_2 的轮廓似然函数的最大值,即为参数的估计值。同时利用无约束寻优算法进行数值优化,提高计算精度和速度。

4 实例验证

为了验证模型的有效性和实用性,采用试验台数据和风力发电机轴承实测振动数据进行验证分析。风力发电机轴承原始振动数据如图 1 所示。



(a) 轴承 1



(b) 轴承 2


图 1 轴承原始振动数据

Fig. 1 Original vibration data of bearings


1) 轴承 1 来自 IEEE PHM2012 提供的轴承退化全寿命数据(每隔 10 s 采集 1 次振动信号,并存储 1 个 0.1 s 时长的振动信号,采样频率为 25.6 kHz)^{[21]401-402}。

2) 轴承 2 来自某风场 1.5 MW 风力发电机自由端轴承的监测数据(采样频率为 25.6 kHz,每天采样若干次,采样时间为 1.28 s)^{[11]250-251}。

风力发电机组标准 VDI 3834 提出,风电机组的健康状态可以通过有效值来体现,故本文采用轴承振动信号特征量的有效值作为其退化状态的指标^[22],退化指标如图 2 所示,其中轴承 2 采用每天多组监测数据的有效值的平均值作为退化指标。



(a) 轴承 1



(b) 轴承 2

图 2 退化指标

Fig. 2 Degradation index

在确定失效阈值时参考 XJTU-SY 试验台方法^{[21]401-402},取轴承正常运行健康指标的 10 倍作为失效阈值,失效阈值如表 1 所示。

表 1 失效阈值


Tab. 1 Failure thresholds

轴承编号	1	2
失效阈值/(m/s ²)	8	20


在进行轴承的寿命预测时,若基于多阶段非线性维纳过程,所选用的退化指标增量需符合高斯分布。轴承的退化增量和增量的统计直方图如图 3 所示。经分析,退化增量分别满足 $N(0.008\ 58, 0.189\ 3^2)$ 和 $N(0.262\ 01, 0.739\ 8^2)$ 的高斯分布。同时,由图 3 可知,随着时间的增加,轴承的退化增量不断增大,不同阶段退化增量差距较大,反映出轴承阶段性退化的特点。因此,轴承的退化过程可以使用多阶段非线性维纳过程进行分析。

确定了轴承的退化指标后,根据第 1 节所述的自适应粒子滤波算法,以轴承振动信号的有效值作为观

测值对轴承进行状态估计,并对轴承的退化指标进行修正,修正结果如图 4 所示。




(a) 轴承 1




(b) 轴承 2

图 3 退化增量

Fig. 3 Degradation increment



(a) 轴承 1



(b) 轴承 2

图 4 退化指标的修正结果

Fig. 4 Correction results of degradation indicators

利用第 3.1 节所述的 CUSUM 算法对轴承分段点进行判断,CUSUM 统计图如图 5 所示。由图 5 可知,轴承的退化过程表现出明显的阶段性特征。在初始阶段,由于轴承处于新使用状态,其健康状况优良,因此退化速率相对较低。然而,随着使用时间的累积,进入第 2 阶段后,轴承的健康状态逐渐恶化,退化速率显著加快。轴承退化阶段 2 个轴承的时间变点分别为第 796 个监测时间点和第 75 个监测时间点。




图 5 CUSUM 统计图

Fig. 5 CUSUM control chart

接下来,根据所求变点,结合修正后的退化指标数据,使用第 3.2 节所述的 MLE 算法对轴承退化模型进行参数估计,同时使用无约束寻优算法实现数值优化,提高计算速度和精度。轴承 1、轴承 2 的参数估计结果分别如表 2、表 3 所示。

表 2 轴承 1 的参数估计结果

Tab. 2 Parameter estimation results for bearing 1

时间/s	参数值		
	μ_i	σ_i	$\sigma_{\mu_i}^2$
2 000	0.411	6.292×10^{-6}	2.375×10^{-8}
4 000	0.399	1.404×10^{-5}	1.548×10^{-7}
6 000	0.172	4.847×10^{-5}	1.183×10^{-8}
8 000	0.208	1.156×10^{-5}	5.474×10^{-6}
10 000	0.008	5.120×10^{-5}	3.473×10^{-7}

由表 2、表 3 可知,轴承在退化过程中不同时刻的参数估计值之间具有明显差异。因此,本文采用多阶段维纳过程模型对轴承进行剩余寿命预测。结合上述参数估计结果与第 2.2 节所述的剩余寿命预测方法,得到轴承 1、轴承 2 的剩余寿命预测的概率密度函数曲线,如图 6 所示。

表 3 轴承 2 的参数估计结果

Tab. 3 Parameter estimation results for bearing 2

时间/d	参数值		
	μ_i	σ_i	$\sigma_{\mu_i}^2$
16	0.523	8.282×10^{-4}	2.194×10^{-34}
32	0.714	1.042×10^{-3}	3.937×10^{-34}
48	0.157	4.262×10^{-3}	1.609×10^{-34}
64	0.090	5.983×10^{-3}	2.588×10^{-34}
80	1.062	1.133×10^{-3}	7.680×10^{-35}






图 6 轴承剩余寿命预测的概率密度函数曲线

Fig. 6 Probability density function curves for remaining life prediction of bearings

进一步地,可得到各个监测时刻轴承 1、轴承 2 的剩余寿命预测结果,为了验证本文所提模型的有效性,将其预测的剩余寿命与退化指标未经滤波修正的剩余寿命预测结果进行了对比分析,如图 7 所示。在预测初期,由于数据样本数量较小,预测误差较大,但随着数据样本数量的增加,预测误差逐渐减小,同时本文模型相比于未滤波的模型具有更快的收敛性,提高了预测的准确性。





(b) 轴承 2

图 7 轴承的剩余寿命预测结果

Fig. 7 Prediction results for remaining life of bearings

为了客观、准确地衡量预测结果的准确性,本文采用均方根误差(Root Mean Square Error, RMSE)作为量化分析准确性的指标。表 4 和表 5 分别列出了利用不同模型得出的 2 个轴承的剩余寿命预测结果与其实际寿命之间的均方根误差。由表 4、表 5 可知,随着时间的增加,2 种模型的预测误差整体上逐渐减小。虽然个别时刻未滤波模型的预测误差比本文模型小,但整体上,本文模型的预测准确性优于未滤波模型;并且随着时间的增加,预测准确性有很大的提升。

表 4 轴承 1 预测误差

Tab. 4 Prediction error for bearing 1

时间/s	预测模型	
	本文模型	未滤波模型
300	4.560	47.452
3 360	5.288	8.671
5 790	4.796	2.945
8 480	3.566	15.751
10 470	3.063	17.285

表 5 轴承 2 预测误差

Tab. 5 Prediction error for bearing 2

时间/d	预测模型	
	本文模型	未滤波模型
4	2.618	11.823
24	4.782	8.475
64	4.386	4.521
76	0.852	1.491

5 结论

针对风力发电机轴承的剩余寿命预测,构建了一种自适应粒子滤波与多阶段非线性维纳过程模型,对轴承在不同服役阶段的剩余寿命进行了预测,得到以下主要结论:

1)模型使用自适应粒子滤波算法对轴承的退化指标进行修正,并使用多阶段非线性维纳过程模型反映轴承的退化,实现了风电轴承的阶段性的寿命预测。

2)结合试验台轴承全寿命数据,对风力发电机自

由端轴承进行验证。相较于退化指标未滤波修正所得的预测结果,本文模型预测结果的准确性有很大提升。

3)风力发电机在实际工作过程中,受到多种天气因素及突发情况的影响,可能会出现轴承在不同服役阶段具有不同退化模式的情况。下一步可探究轴承在多种退化模式下竞争失效的剩余寿命预测方法。

参考文献(References)

- [1] 吕明珠. 风电轴承状态监测与智能维护策略研究[J]. 电气开关, 2021, 59(3): 35-40.
LÜ Mingzhu. Research on condition monitoring and intelligent maintenance strategy for wind turbine bearings [J]. Electric Switchgear, 2021, 59(3): 35-40. (In Chinese)
- [2] 李兆飞. 数据驱动的轴承早期故障诊断技术综述[J]. 机械传动, 2023, 47(3): 165-176.
LI Zhao-fei. A survey of incipient fault diagnosis of bearings based on data-drive [J]. Journal of Mechanical Transmission, 2023, 47(3): 165-176. (In Chinese)
- [3] 阮爱国, 沈忠明, 刘发炳, 等. 一种单样本风电机组传动链故障诊断方法[J]. 机械传动, 2024, 48(8): 161-168.
RUAN Aiguo, SHEN Zhongming, LIU Fabing, et al. A single-sample fault diagnosis method of a wind turbine transmission chain [J]. Journal of Mechanical Transmission, 2024, 48(8): 161-168. (In Chinese)
- [4] 赵洪山, 林诗雨, 孙承妍, 等. 考虑多时间尺度信息的风力发电机滚动轴承故障预测[J]. 中国电机工程学报, 2024, 44(22): 8908-8919.
ZHAO Hongshan, LIN Shiyu, SUN Chengyan, et al. Fault prediction of wind turbine rolling bearing considering multi-time scale information [J]. Proceedings of the CSEE, 2024, 44(22): 8908-8919. (In Chinese)
- [5] 张金豹, 邹天刚, 王敏, 等. 滚动轴承剩余使用寿命预测综述[J]. 机械科学与技术, 2023, 42(1): 1-23.
ZHANG Jinbao, ZOU Tiangang, WANG Min, et al. Review on remaining useful life prediction of rolling bearing [J]. Mechanical Science and Technology for Aerospace Engineering, 2023, 42(1): 1-23. (In Chinese)
- [6] 邱明, 牛凯岑, 李军星, 等. 多重应力下滚动轴承剩余寿命预测[J]. 航空动力学报, 2022, 37(5): 980-988.
QIU Ming, NIU Kaicen, LI Junxing, et al. Residual life prediction of rolling bearing under multiple stresses [J]. Journal of Aerospace Power, 2022, 37(5): 980-988. (In Chinese)
- [7] SI X S, WANG W B, HU C H, et al. Remaining useful life estimation: a review on the statistical data driven approaches [J]. European Journal of Operational Research, 2011, 213(1): 1-14.
- [8] LI C, DE OLIVEIRA J V, CERRADA M, et al. A systematic review of fuzzy formalisms for bearing fault diagnosis [J]. IEEE Transactions on Fuzzy Systems, 2019, 27(7): 1362-1382.
- [9] TANGKUMAN S, YANG B S. Application of grey model for machine degradation prognostics [J]. Journal of Mechanical Science and Technology, 2011, 25(12): 2979-2985.
- [10] 金晓航, 李建华, 孙毅. 基于二元维纳过程的轴承剩余寿命预测[J]. 仪器仪表学报, 2018, 39(6): 89-95.
JIN Xiaohang, LI Jianhua, SUN Yi. Bearing remaining useful life prediction based on two-dimensional Wiener process [J]. Chinese

- Journal of Scientific Instrument, 2018, 39(6): 89-95. (In Chinese)
- [11] 丁显, 徐进, 黎曦琳, 等. 融合维纳过程和粒子滤波的风力发电机轴承剩余寿命预测[J]. 太阳能学报, 2022, 43(12): 248-255.
DING Xian, XU Jin, LI Xilin, et al. Remaining life prediction of wind turbine bearing based on Wiener process and particle filter [J]. Acta Energaie Solaris Sinica, 2022, 43 (12) : 248-255. (In Chinese)
- [12] GUO J Y, WANG Z Y, LI H, et al. A hybrid prognosis scheme for rolling bearings based on a novel health indicator and nonlinear Wiener process [J]. Reliability Engineering & System Safety, 2024, 245: 110014.
- [13] WU B, ZENG J C, SHI H, et al. Remaining useful life prediction for multiple degradation indicators systems considering random correlation [J]. Computers & Industrial Engineering, 2023, 186: 109736.
- [14] WANG X L, GAUDOIN O, DOYEN L, et al. Modeling multivariate degradation processes with time-variant covariates and imperfect maintenance effects [J]. Applied Stochastic Models in Business and Industry, 2021, 37(3): 592-611.
- [15] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J]. 高电压技术, 2024, 50(3): 1182-1195.
XIONG Qing, DI Zhenguo, JI Shengchang. Review on health state estimation and life prediction of lithium-ion batteries [J]. High Voltage Engineering, 2024, 50(3): 1182-1195. (In Chinese)
- [16] HONG S D, QIN C K, LAI X, et al. State-of-health estimation and remaining useful life prediction for lithium-ion batteries based on an improved particle filter algorithm [J]. Journal of Energy Storage, 2023, 64: 107179.
- [17] 张新雨, 任梦姣, 弋英民, 等. 一种混合自适应重采样的智能粒子滤波[J/OL]. 控制理论与应用, 2024: 1-9 (2024-08-30) [2024-09-12]. <https://link.cnki.net/urlid/44.1240.TP.20240830.1358.063>.
ZHANG Xinyu, REN Mengjiao, YI Yingmin, et al. An intelligent particle filter with hybrid adaptive resampling [J/OL]. Control Theory & Applications, 2024: 1-9 (2024-08-30) [2024-09-12]. <https://link.cnki.net/urlid/44.1240.TP.20240830.1358.063>. (In Chinese)
- [18] PANG H, CHEN K Q, GENG Y F, et al. Accurate capacity and remaining useful life prediction of lithium-ion batteries based on improved particle swarm optimization and particle filter [J]. Energy, 2024, 293: 130555.
- [19] ZHANG J X, HU C H, HE X, et al. A novel lifetime estimation method for two-phase degrading systems [J]. IEEE Transactions on Reliability, 2019, 68(2): 689-709.
- [20] 牛一凡, 邵景峰. 基于非线性数据融合的设备多阶段寿命预测[J]. 信息与控制, 2019, 48(6): 729-737.
NIU Yifan, SHAO Jingfeng. Multistage lifetime estimation for equipment based on nonlinear data fusion [J]. Information and Control, 2019, 48(6): 729-737. (In Chinese)
- [21] WANG B, LEI Y G, LI N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.
- [22] International Organization for Standardization. Mechanical vibration—evaluation of machine vibration by measurements on non-rotating parts: part 21: horizontal axis wind turbines with gearbox: ISO 10816-21: 2015 [S]. Geneva: International Organization for Standardization, 2015: 5-7.

Residual life prediction of wind turbine bearings based on adaptive particle filtering and nonlinear Wiener process

SONG Debo¹ QI Wenzhe¹ QI Jinping^{1, 2}

(1. School of Mechanical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

(2. Research Institute, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: [Objective] Aiming at the problem that wind power bearings are interfered by nonlinear factors and non-Gaussian noise during the monitoring process, and the degradation showing stage characteristics, a model combining adaptive particle filtering with a multi-stage nonlinear Wiener process was constructed. [Methods] Firstly, the Wiener process was introduced into the state-space model of particle filtering to enhance the nonlinear expression ability of the model. Meanwhile, the sampling process was adjusted using an adaptive sampling strategy to effectively avoid particle degradation, thus improving the accuracy of the state estimation and correcting the bearing degradation index. Secondly, a degradation model of bearings was established based on the multi-stage nonlinear Wiener process, and the drift coefficients were randomized by taking into account the variability of different individual bearings. The segmentation points of the degradation stages of bearings were determined by the cumulative sum algorithm, and the model parameters were estimated using the maximum likelihood estimation algorithm. Finally, verification and analysis were conducted on the test bench data and the monitoring data of the free-end bearings of the wind turbine, and the remaining life prediction results obtained by the proposed method were compared with those obtained from the degradation index without filtering correction. [Results] The results show that the proposed method has higher prediction accuracy.

Key words: Wind turbine; Rolling bearing; Adaptive particle filtering; Multi-stage nonlinear Wiener process; Residual life prediction

Corresponding author: QI Wenzhe, E-mail: qiwz@mail.lzjtu.cn

Fund: Key Research and Development Program of Gansu Province (23YFGA0050)

Received: 2024-10-11 Revised: 2024-11-28

(编辑: 刘星泽)