

联合频域相关分析和改进粒子滤波的滚动轴承寿命预测方法

梁洁琳¹, 丁康¹, 何国林^{1,2}, 林慧斌¹, 蒋飞¹

(1. 华南理工大学机械与汽车工程学院, 广东广州 510640; 2. 琶洲实验室, 广东广州 510335)

摘要: 为了解决滚动轴承退化状态识别难、剩余使用寿命(Remaining Useful Life, RUL)预测误差大这两个关键问题,提出一种联合频域特征相关分析及改进粒子滤波的寿命预测方法。基于滚动轴承在退化过程中频域特征存在短期相似性和长期差异性这一特点,对不同时间序列傅里叶变换后的幅值谱进行相关分析,构建平均相关系数(Average Correlation Coefficient, ACC)曲线。当 ACC 达到设定阈值时,利用初始故障时间(Degradation Initial Timepoint, DIT)将轴承状态划分为正常和损伤两阶段。利用损伤阶段的归一均方根值作为观测样本输入,构建考虑了全局指数式退化趋势与局部波动双重因素的粒子滤波(Dual Factor Particle Filter, DFPPF)模型,实现粒子分布校正并完成 RUL 预测。试验结果表明,所提方法相比传统的均方根值法和峭度法能够更准确地识别轴承初始故障时间。在寿命预测精度方面,相比传统粒子滤波(Particle Filter, PF)算法,所提方法减小了异常观测值对预测趋势的影响,具有更高的 RUL 预测精度。

关键词: 剩余使用寿命预测; 滚动轴承; 频域相关分析; 状态划分; 粒子滤波

中图分类号: TB114.33; TH133.33 **文献标志码:** A **文章编号:** 1004-4523(2023)06-1736-08

DOI: 10.16385/j.cnki.issn.1004-4523.2023.06.028

引言

滚动轴承作为旋转机械的关键部件,其退化状态影响机械设备的安全可靠性能。准确的轴承寿命预测有利于预防性维护系统,避免轴承突然失效而导致设备发生致命故障^[1-4]。其中,运行状态划分和剩余使用寿命预测是轴承寿命预测框架中的两个重要问题。

目前常用的轴承正常运行和损伤运行阶段划分的方法为通过合理的阈值准则选取退化初始时间(DIT)^[5]。Niu 等^[6]应用国际规范的轴承阈值基准线和报警系数获取融合指标的 DIT。申彦斌等^[7]提出一种基于卷积自编码器的轴承健康指标(Health Indicator, HI)构建方法,根据所提 HI 的变化规律人为划分三个运行阶段;Hong 等^[8]利用自组织映射网络构成全寿命退化评估曲线并手动设定正常和早期退化的阈值界限。然而,以上方法均基于大量统计特性或数据经验主观选取,没有进一步验证 DIT 结果的合理性,对于单个系统而言,所选 DIT 可能会

滞后或提前,导致检修延迟或误预警。

基于数据驱动的轴承寿命预测方法主要包括机器学习 and 统计模型两种方法。前者结合大量可用数据样本预测退化趋势,适用于处理复杂机械系统的 RUL 预测问题^[9-10]。但受限于成本和时间耗费,实际应用中难以获取高质量数据样本,增加了 RUL 预测难度。而统计模型预测方法的优势在于同时结合先验数学^[11-12]或物理^[13-14]模型以及最新数据样本以更新未知参数,相对简单易行。其中,基于指数模型的传统粒子滤波算法广泛应用于锂电池、飞行器等^[15-16]不同对象的 RUL 预测领域。滚动轴承的全寿命退化过程也与指数模型相似,但由于受损伤演变特性^[17]或随机误差的影响,表征轴承退化过程的观测指标会局部偏离全局指数模型,呈上下非线性波动,导致传统粒子滤波的预测曲线偏离实际退化趋势,降低寿命预测精度。

综上,本文提出了联合频域相关分析和改进粒子滤波算法驱动的滚动轴承寿命预测方法。基于滚动轴承在退化过程中振动响应信号频域特征具有短期相似和长期差异这一特性,构建平均相关系数曲

收稿日期: 2022-01-05; **修订日期:** 2022-03-10

基金项目: 国家自然科学基金资助项目(52075182);广州市科技计划基础与应用基础研究项目(202102020602);广东省自然科学基金资助项目(2020A1515010972,2020A1515010750)。

线,识别合适的早期退化时间,并结合小波降噪和希尔伯特包络解调方法验证所选DIT的准确性。由于观测值的局部波动,传统粒子滤波的粒子后验分布也会相应偏离真实分布,导致RUL预测精度降低。因此构建了一个同时考虑全局指数式退化趋势与局部波动双重因素的改进粒子滤波算法。所提方法通过新构造的粒子约束器校正粒子分布,引导粒子的后验概率密度朝真实退化值更新,实现更高精度的寿命预测。

1 ACC-DFPF 滚动轴承寿命预测方法

1.1 基于频域相关分析的ACC区间划分

均方根(Root Mean Square, RMS)具有较好的单调性,且能有效反映振动能量,该时域特征常作为轴承的健康指标。然而,RMS在早期故障时间前后的幅值变化不明显,难以直接准确识别DIT。实际上,故障特征频率作为轴承发生故障的机理特性之一,频域幅值和频率倍频会在轴承不同的退化状态存在差异。基于此,通过构建平均相关系数(ACC)曲线和所设阈值识别RMS的DIT,具体步骤如图1所示。

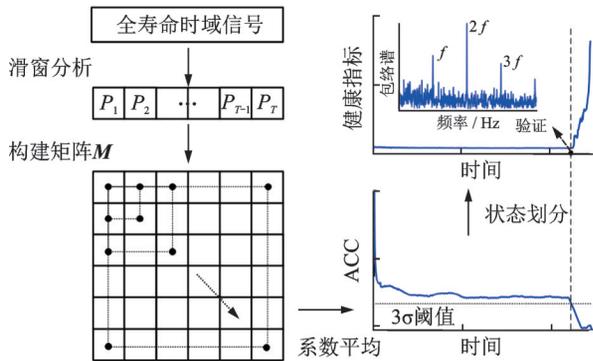


图1 滚动轴承状态区间划分流程

Fig. 1 Process of rolling bearing state division

a) 对滚动轴承的全寿命振动响应时域信号做滑窗采样,并相应进行快速傅里叶变换得到幅值谱 $P_k (k=1, 2, \dots, T)$, T 为幅值谱总个数;

b) 运用 Pearson 相关系数评价任意两幅值谱的相关程度,如下式:

$$\rho_{st} = \frac{\sum_{n=1}^N (P_{s,n} - \bar{P}_s)(P_{t,n} - \bar{P}_t)}{\sqrt{\sum_{n=1}^N (P_{s,n} - \bar{P}_s)^2 \sum_{n=1}^N (P_{t,n} - \bar{P}_t)^2}} \quad (1)$$

构建相关系数矩阵 M :

$$M = \begin{bmatrix} \rho_{11} & \rho_{12} & \cdots & \rho_{1T} \\ \rho_{21} & \rho_{22} & \cdots & \rho_{2T} \\ \vdots & \vdots & \vdots & \vdots \\ \rho_{T1} & \rho_{T2} & \cdots & \rho_{TT} \end{bmatrix} \quad (2)$$

式中 ρ_{st} 为第 s 和第 t 个幅值谱之间的相关系数, $s, t=1, 2, \dots, T$; $P_{s,n}, P_{t,n}$ 分别对应第 s 和第 t 个幅值谱的第 n 条谱线频率值; $N, \bar{P}_s = \sum_{n=1}^N P_{s,n} / N$ 和 $\bar{P}_t = \sum_{n=1}^N P_{t,n} / N$ 分别为每个幅值谱的谱线数,第 s 和第 t 个幅值谱的谱线频率均值。

c) 为直观地反映起始健康信号与后续每段信号的相关程度变化,计算一维 ACC 曲线,计算式为: $ACC = (\rho_{11} + \rho_{1i} + \rho_{i1} + \rho_{ii}) / 4, i=1, 2, \dots, T$ (3)

结合 3σ 阈值识别 DIT,最后用小波降噪和包络解调谱验证结果的准确性。

1.2 传统粒子滤波(PF)算法框架

粒子滤波通过蒙特卡罗方法(Monte Carlo, MC)避免贝叶斯递推过程中的高维积分计算,得到粒子后验概率分布和样本均值,从而估计非线性系统的状态。滚动轴承的退化趋势常用指数模型描述,其时变系统的状态方程和观测方程分别为:

$$\begin{cases} a_k = a_{k-1} + u_k \\ b_k = b_{k-1} + v_k \\ y_k = x_k + \chi_k = a_k \exp(b_k k) + \chi_k \end{cases} \quad (4)$$

式中 u_k 和 v_k 分别对应 k 时刻未知模型参数 a_k 和 b_k 的过程误差; y_k 和 x_k 分别为 k 时刻的系统观测指标和模型状态值,两者存在观测误差 χ_k ; u_k, v_k, χ_k 分别服从标准差为 $\sigma_u, \sigma_v, \sigma_r$ 的正态分布 $N(0, \sigma_u^2), N(0, \sigma_v^2), N(0, \sigma_r^2)$ 。

传统粒子滤波算法基于式(4)进行预测和更新。

a) 预测过程。已知第 1 至 $k-1$ 时刻的系统观测值 $y_{1:k-1}$ 和参数向量 Θ_{k-1} ,采用一组粒子数为 N_p 的粒子描述 k 时刻参数的先验概率分布 $P(\Theta_k | \Theta_{k-1}, y_{1:k-1})$ 。基于式(4),第 j 个粒子的参数预测向量 Θ_k^j 和模型状态值 x_k^j 分别为:

$$\begin{cases} \Theta_k^j = \begin{bmatrix} a_k^j \\ b_k^j \end{bmatrix} = \begin{bmatrix} a_{k-1}^j + u_k^j \\ b_{k-1}^j + v_k^j \end{bmatrix} \\ x_k^j = a_k^j \exp(b_k^j k) \end{cases} \quad (5)$$

b) 更新过程。第 k 时刻获取观测值 y_k 时,采用下式更新和归一化每个预测粒子的权重 ω_k^j :

$$\omega_k^j = \omega_{k-1}^j \frac{1}{\sqrt{2\pi} \sigma_r} \exp\left[-\frac{1}{2} \left(\frac{y_k - x_k^j}{\sigma_r}\right)^2\right] \quad (6)$$

$$\omega_k^j = 1 / \sum_{j=1}^{N_p} \omega_k^j \quad (7)$$

当有效粒子数 $N_{\text{eff}} = 1 / \sum_{j=1}^{N_p} (\omega_k^j)^2 < N_p/2$ 时,采

用随机重采样生成新的权重集,解决粒子更新过程中的粒子退化问题^[18]。

此时输出 k 时刻的指标估计值 \hat{x}_k :

$$\hat{x}_k = \sum_{j=1}^{N_p} \omega_k^j x_k^j \quad (8)$$

当不再输入观测值时,重复 a) 步骤继续递推预测后续轴承健康指标值 \hat{x}_k 。轴承剩余使用寿命预测值 \widehat{RUL}_h 为 \hat{x}_k 首次超过失效阈值 γ 对应的时刻 \hat{k}_T 与最后输入观测值时刻 k_h 的时间差值。

相同输入数据样本个数下,采用实际剩余使用寿命 RUL_h 和 \widehat{RUL}_h 的相对误差 Er_h 评价预测精度:

$$Er_h = \left| \frac{\widehat{RUL}_h - RUL_h}{RUL_h} \right| \times 100\% \quad (9)$$

1.3 改进粒子滤波驱动的轴承 RUL 预测

由式(6)可知,PF算法的粒子权重更新主要依赖最新观测值。当输入的最后观测值偏离全局退化值时,PF算法后续预测的轴承退化轨迹会偏离真实趋势,如图2所示。 A_1 和 A_1' 分别为实际观测值和全局模型值,当 $A_1 > A_1'$ 时,PF预测曲线比真实趋势更早到达失效阈值,高估了实际故障严重程度;反之预测值比真实趋势更平缓,以上两种局部波动观测值均降低了传统PF算法的轴承RUL预测精度。

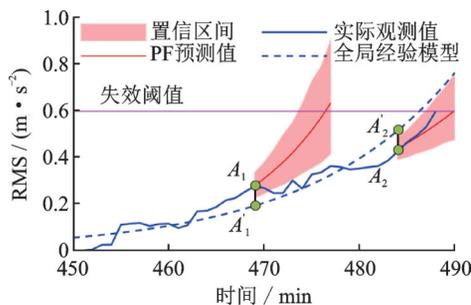


图2 传统粒子滤波的预测趋势

Fig. 2 Trends predicted by conventional particle filter

因此,在原有PF方法的更新过程中,新构造一个同时考虑全局模型参数和局部观测值的约束器,形成改进粒子滤波。所提约束器引导粒子分布朝向全局退化值更新,抑制局部波动观测值对轴承HI预测结果的干扰。具体步骤为:

1) 构建 k 时刻的粒子损失函数 $L_k(\Theta^j, k)$:

$$L_k(\Theta^j, k) = (1 - \lambda_k) (y_k - x_k^j)^2 + \lambda_k \left[\left(\frac{\partial x_k^j}{\partial a_k^j}, \frac{\partial x_k^j}{\partial b_k^j} \right) \cdot (\Theta^j - \Theta_0) \right]^2 \quad (10)$$

式中 $\Theta_0 = [a_0 \ b_0]^T$ 为全局经验模型参数; λ_k 为第 k 时刻权重系数, $\left(\frac{\partial x_k^j}{\partial a_k^j}, \frac{\partial x_k^j}{\partial b_k^j} \right)$ 表示第 k 时刻对第 j 个粒子的模型参数 a_k^j 和 b_k^j 求偏微分; Θ_k^j 为第 k 时刻的第 j 个粒子在预测过程的模型参数预测向量。

2) k 时刻的权重系数 $\lambda_k \in [0, 1]$ 表示为:

$$\lambda_k = (1 - c) \cdot \max \left\{ 0, 1 - \frac{|y_k - a_0 \exp(b_0 k)|}{\delta} \right\} + c \lambda_{k-1} \quad (11)$$

式中 c 和 δ 均为常数因子。令 $x_{0,k} = a_0 \exp(b_0 k)$ 为 k 时刻的全局模型估计值。

3) 第 j 个粒子的参数预测向量 Θ_k^j 校正为:

$$\Theta_k^j = \Theta_k^j - \eta \left[\frac{\partial L_k(\Theta_k^j, k)}{\partial a_k^j}, \frac{\partial L_k(\Theta_k^j, k)}{\partial b_k^j} \right] \quad (12)$$

$$\text{令 } \nabla_{\Theta} L_k = \left[\frac{\partial L_k(\Theta_k^j, k)}{\partial a_k^j}, \frac{\partial L_k(\Theta_k^j, k)}{\partial b_k^j} \right] \text{ 为 } a_k^j \text{ 和 } b_k^j$$

的梯度公式, $\eta = [\eta_1 \ \eta_2]^T$ 为模型参数的学习率。

利用 Θ_0 和 y_k 计算损失函数,目的是通过平滑的全局模型趋势和输入观测值同时约束粒子分布,减弱输入样本对后续预测曲线的影响。此外,依据 y_k 和 $x_{0,k}$ 的差异程度,权重系数 λ_k 可自适应调整式(10)的两项权重。

综上,所提ACC-DFPF滚动轴承寿命预测方法流程如图3所示,具体说明如下:

a) 采集轴承数据,对各段频谱进行相关分析,构建ACC曲线,结合所设阈值识别DIT,完成HI指标的 normal 和损伤状态划分,并依据小波降噪包络解调谱的故障频率成分验证DIT的准确性。

b) 采用最小二乘法拟合轴承损伤区间的HI指标,计算全局模型经验参数 $\Theta_0 = [a_0 \ b_0]^T$, Θ_0 也作为DFPF算法的初始化参数输入DFPF算法。当 k 时刻获取 y_k 时,采用式(10)~(12)所提约束器校正粒子预测过程的先验分布,随后进行粒子权重更新和重采样,直至再无观测值输入时,粒子校正停止。

c) 继续采用式(5)和式(8)计算,输出轴承从最后观测值时刻 k_h 至预测失效时刻 \hat{k}_T 的HI指标估计值 \hat{x}_k 和估计寿命值 \widehat{RUL}_h 。

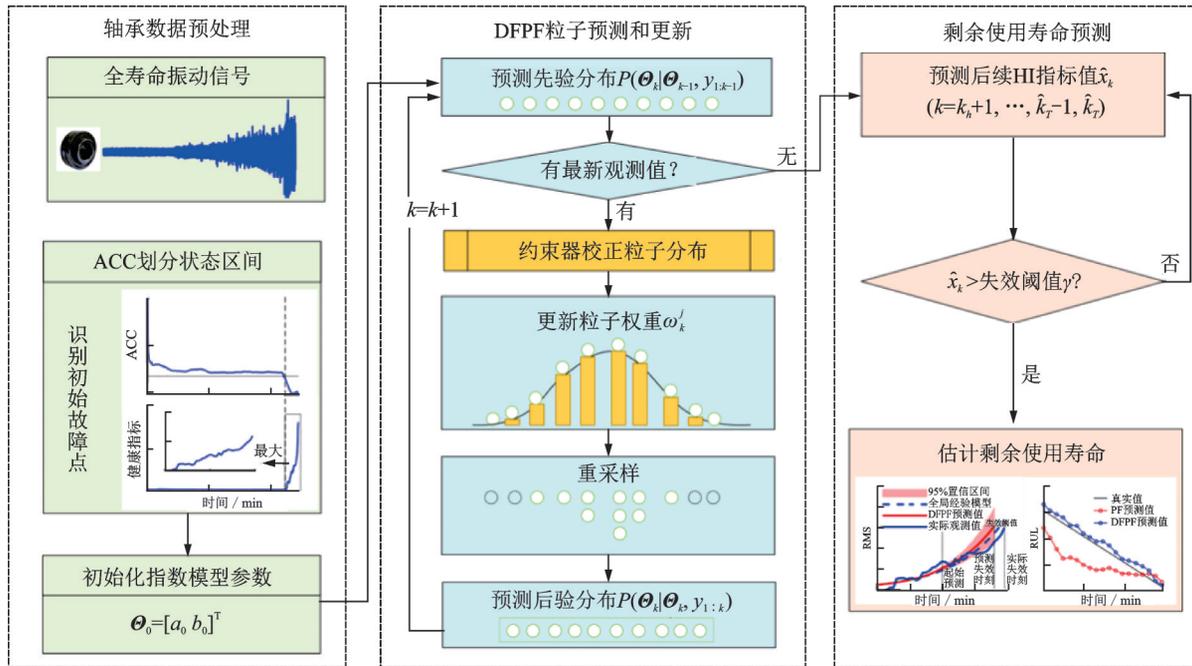


图 3 ACC-DFPF 滚动轴承寿命预测方法流程

Fig. 3 Flowchart of ACC-DFPF method for rolling bearing life prediction

2 试验验证

2.1 ACC划分区间方法的分析对比

选择XJTU-SY滚动轴承全寿命试验数据集^[19]验证所提方法的有效性。测试平台的采样频率为2.56 kHz,每间隔1 min采样1.28 s,在3类工况下各重复5次试验,共计15组轴承全寿命时间序列样本。其中,bearing3-1发生外圈磨损。

以轴承 bearing3-1 为例,所得 ACC 退化曲线和 DIT 点如图 4 所示。初始运行时系统不稳定,对应 ACC 值产生幅度波动。健康状态阶段的轴承平均相关系数相对平稳,随后在初始故障位置开始减小,并在损伤阶段随退化程度加深而整体减小。图 4 中,ACC 值在 500~1500 min 内相对稳定,由此得到 3σ 阈值下限为 0.6106,在第 2371 min 首次超过阈值,表明此时该轴承发生初始故障。

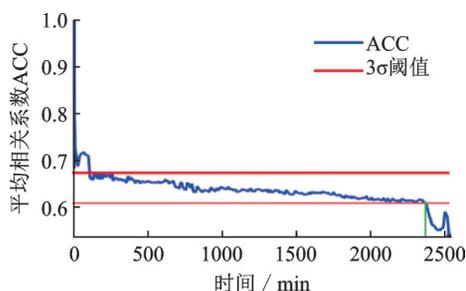


图 4 ACC 识别起始故障点结果

Fig. 4 The DIT identification result with ACC model

进一步采用小波降噪和包络解调验证所选 DIT 的准确性。考虑早期轴承故障特征微弱,先用小波降噪减弱信号样本的噪声干扰。由图 5 降噪包络谱可知,第 2369 min 未出现故障特征频率成分,而第 2371 和第 2373 min 均出现了与外圈故障特征频率理论值 123.32 Hz 接近的频谱成分,且第 2530 min 轴承故障程度严重,故障频率与倍频的幅值都增大,验证了轴承在第 2371 min 存在早期故障。

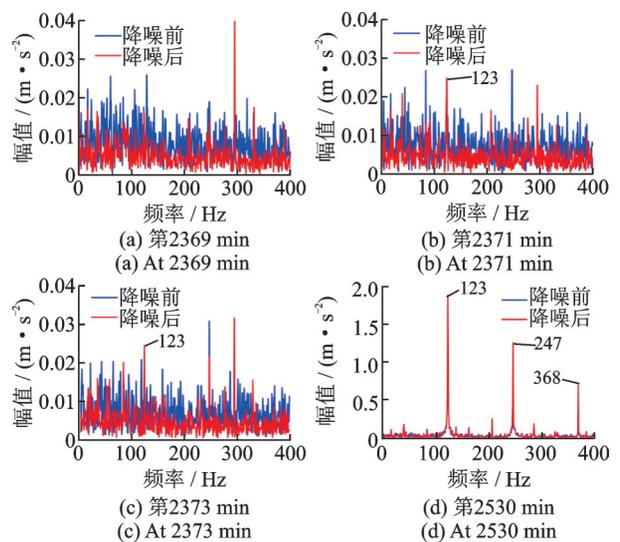


图 5 不同时刻的轴承包络谱

Fig. 5 Envelope spectrums of bearing at different moments

此外,将所提方法与时域特征 RMS、峭度 kurtosis 和频域特征频谱重心 (Frequency Center, FC) 识别 DIT 方法的结果进行对比。bearing3-1 的

RMS在第2340 min后均超过上限阈值,如图6所示,说明RMS比ACC方法提早31 min推断轴承发生早期故障。但图7中的第2340和2350 min降噪解调谱未有明显的故障特征频率谱峰。此外,RMS整体比ACC曲线振荡,且在第2340 min前有多处异常RMS超过阈值造成DIT的错误预警。

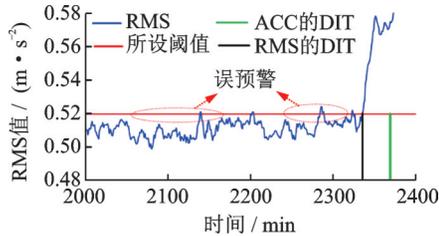


图6 RMS识别起始故障点结果

Fig. 6 The DIT identification result with RMS model

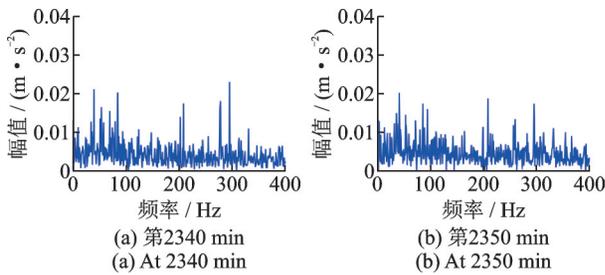


图7 第2340和2350 min的降噪包络谱

Fig. 7 Denoising envelope spectrum at 2340 and 2350 min

峭度方法识别DIT的结果如图8所示,在第2523 min后均超过上限阈值,推断该时刻发生了轴承初始故障,比ACC方法延迟152 min,对应检验了包络谱有突出的故障频率谱峰。此外,在第2371 min前有多处超过所设阈值的剧烈波动峭度,和RMS方法存在类似的误预警现象。

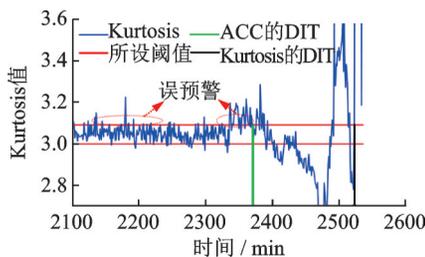


图8 Kurtosis识别起始故障点结果

Fig. 8 The DIT identification result with kurtosis model

频谱重心识别DIT如图9所示。分别求取[0, 2000] min和[2400, 2454] min上升和下降区间的FC值斜率,交叉点位于第2346 min,初步推断该时刻发生轴承初始故障,相比ACC方法提前25 min识别了DIT。此外,该轴承的FC指标相较于ACC和以上时域特征整体单调性较差。

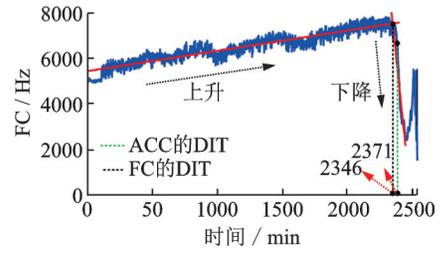


图9 FC识别起始故障点结果

Fig. 9 The DIT identification result with FC model

综上,ACC方法可以比时域RMS,kurtosis和频域FC方法更准确地识别出轴承初始故障点,且ACC曲线整体更平滑,避免错误预警早期故障点的情况,为下一步进行轴承剩余寿命预测提供起始点依据。

2.2 DFPF方法预测轴承RUL的分析对比

选取包括同一尺寸3个工况的bearing1-3, bearing2-1和bearing3-1作为算法验证数据集。结合3类运行工况共6组历史轴承的退化规律选取统一的失效阈值。对RMS健康指标进行最大、最小值归一化,避免了不同工况下因轴承HI数值差异较大导致失效阈值 γ 难选择的问题,如图10所示。图10(b)的RMS值在0.6以上均变化陡峭,表明该阈值后轴承加速劣化至完全损坏,因此设定失效阈值 $\gamma=0.6$ 。

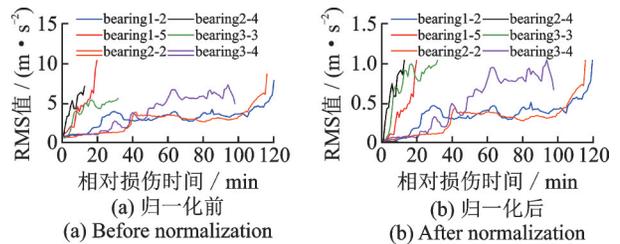


图10 6组轴承数据的HI曲线

Fig. 10 Six sets of bearing health indicator curves

基于ACC方法和 γ 确定表1验证数据集的DIT和实际失效时刻 k_T ,采用最小二乘法拟合对应HI指标值得到全局经验模型参数 a_0, b_0 以及标准差 σ_q, σ_r 和 σ_v 。其中,初始权重系数取 $\lambda_0=1$ 表示没有观测值输入时,粒子的校正完全依赖所得全局经验模型参数。DFPF算法的主要结构参数如表2所示。

表1 验证数据集的DIT和失效时刻

Tab. 1 DIT and actual degradation time of the testing data

轴承	DIT/min	实际失效时刻 k_T /min
bearing1-3	60	153
bearing2-1	450	488
bearing3-1	2371	2535

分别输入特定观测值比例,采用所提DFPF算法得到一系列指标预测值 \hat{x}_i ,与PF算法结果相比,如图11所示。

表 2 DFPF 算法主要结构参数

Tab. 2 The main structural parameters of DFPF algorithm

轴承	N_p	a_0	b_0	σ_q	σ_r	σ_v	η_1	η_2
bearing1-3	500	8.065×10^{-2}	3.184×10^{-2}	5×10^{-4}	1×10^{-4}	5×10^{-2}	10^{-4}	10^{-3}
bearing2-1	500	5.144×10^{-2}	6.587×10^{-2}	5×10^{-3}	8×10^{-4}	5×10^{-2}	10^{-8}	10^{-2}
bearing3-1	500	9.237×10^{-3}	2.389×10^{-2}	5×10^{-4}	1×10^{-4}	5×10^{-2}	10^{-4}	10^{-3}

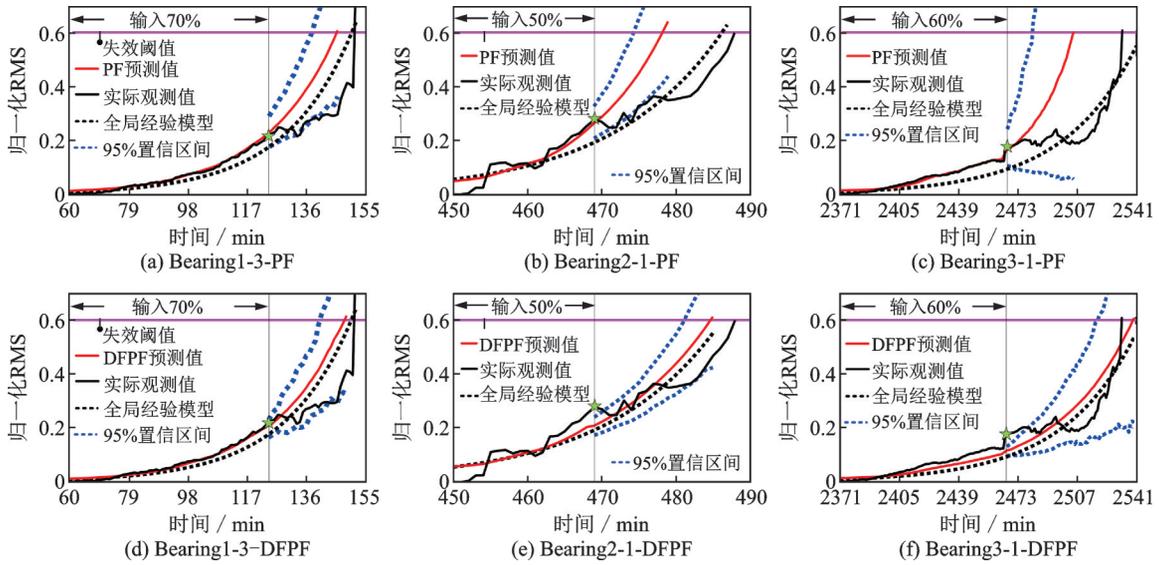


图 11 DFPF 和 PF 算法所得性能退化预测曲线

Fig.11 Performance degradation prediction curves obtained by DFPF and PF algorithm

对于轴承 bearing2-1, 50% 的样本输入比例对应最后输入观测值的时刻约为第 469 min, 该局部观测数据可能受测量过程的噪声随机影响或是退化演变波动特性, 偏离了全局经验模型。由于 PF 算法输出的预测值主要依赖于最后输入的观测值, 该预测失效时刻比实际失效时刻提早 12 min, 而所提 DFPF 方法更为有效, 仅提早了 5 min。原因在于所提 DFPF 方法有全局

模型参数和局部观测值这两项共同约束粒子分布, 降低了后续预测结果对局部波动数据的敏感性, 使得轴承未来状态的预测值比传统 PF 算法更趋近真实观测曲线。同理对于轴承 bearing1-3 和 bearing3-1, DFPF 预测曲线的 95% 置信区间间距更窄, RUL 相对误差更小, 具体如表 3 所示。由以上分析可知, 所提 DFPF 算法预测轴承剩余寿命精度优于 PF 算法。

表 3 特定时间段下轴承 RUL 预测误差结果

Tab. 3 Results of bearing RUL prediction error under a specific time period

轴承	方法	开始预测时刻/min	\widehat{RUL}/min	RUL_i/min	$Er_i/\%$
bearing1-3	DFPF	125	25	28	10.71
	PF	125	22	28	21.43
bearing2-1	DFPF	469	14	19	26.32
	PF	469	7	19	63.16
bearing3-1	DFPF	2471	73	64	12.33
	PF	2471	38	64	40.63

为了更直观地说明不同时间段下所提 DFPF 算法的预测优势, 按 5%, 10%, 15%, ..., 95% 共 19 组不同的观测值输入比例预测轴承剩余使用寿命, 如图 12 所示。

此外, 分别用均方根误差 E_{rmse} 、平均绝对百分比误差 E_{mape} 和平均绝对误差 E_{mae} 指标评价两种算法的 RUL 预测精度, 具体计算公式为:

$$E_{\text{rmse}} = \sqrt{\frac{1}{19} \sum_{i=1}^{19} (\widehat{RUL}_i - RUL_i)^2} \quad (13)$$

$$E_{\text{mape}} = \sum_{i=1}^{19} \left| \frac{\widehat{RUL}_i - RUL_i}{RUL_i} \right| \times \frac{100\%}{19} \quad (14)$$

$$E_{\text{mae}} = \frac{1}{19} \sum_{i=1}^{19} |\widehat{RUL}_i - RUL_i| \quad (15)$$

式中 \widehat{RUL}_i 和 RUL_i 分别表示在同一个输入比例 i 下对应的预测和真实剩余使用寿命值。

以上指标越小代表预测精度越高, 具体结果对比如表 4 所示。

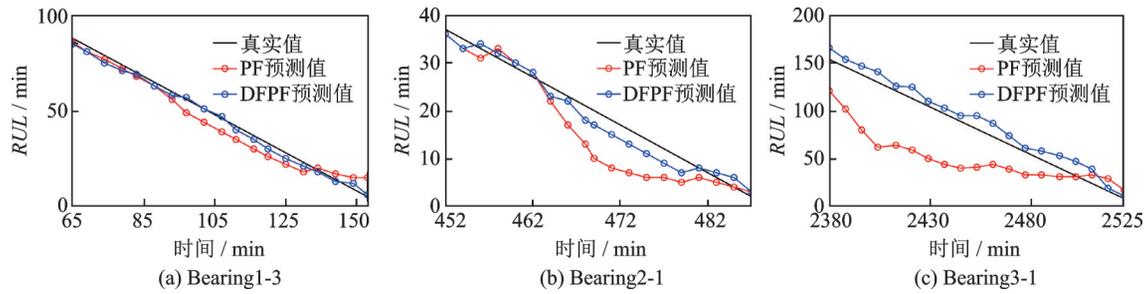


图12 不同起始预测时刻的轴承RUL曲线

Fig. 12 RUL curves of bearings at different initial prediction moments

当输入观测值比例为较少的5%时,轴承RUL预测结果对应输出图12(a)~(c)的左起第一个点,可直观看出其接近实际值。其原因可能是预测结果受初始模型参数影响,而以上轴承的初始模型参数均由对应的全局指标数据拟合得出,准确度较高,因此即使观测样本较少,RUL预测结果仍会接近真实寿命。此外,对于bearing2-1和bearing1-3,占比为10%至30%对应的预测RUL也接近真实值,进一步分析原因可能是该比例下的实际观测值波动较小,整体较接近全局经验模型。以上分析可知在输入观测值个数不足的情况下,观测值和初始模型参数会影响轴承RUL预测。

表4 不同起始预测时刻的轴承RUL误差

Tab. 4 RUL errors for bearings at different initial prediction moments

轴承	方法	误差分析指标		
		E_{rmse}	$E_{mape}/\%$	E_{mae}
bearing1-3	PF	5.3607	24.13	4.7368
	DFPF	2.2478	6.960	2.0000
bearing2-1	PF	5.3114	27.10	1.8421
	DFPF	2.0901	15.37	0.2710
bearing3-1	PF	39.5867	45.45	34.0526
	DFPF	9.9552	17.61	9.1053

3 结论

(1) 构造了表征轴承退化性能的ACC曲线,准确地定位了轴承起始故障点,并采用小波降噪和希尔伯特包络解调方法辅助验证所选点的早期故障情况。由XJTU-SY轴承数据集的验证结果对比可知,所提ACC方法相较于均方根和峭度方法能够更准确找到早期故障点,实现轴承正常与损伤两个状态阶段的有效划分。

(2) 所提DFPF算法构造了含有全局模型参数和局部实际观测值的约束器用于校正粒子分布,克服传统粒子滤波算法受观测值波动干扰的缺陷。XJTU-SY轴承数据集的试验结果表明,所提DFPF算法后续预测的健康指标值比PF算法更接近全局运行状态,置信区间宽度和相对误差 Er_h 均更小,实

现了更准确的轴承寿命估计。

(3) 输入不同数目观测数据的试验结果表明,DFPF算法可以有效减少轴承局部异常波动观测数据对轴承RUL预测结果的影响,其RUL的 E_{rmse} , E_{mape} 和 E_{mae} 误差均小于PF算法,实现了更可靠的寿命预测。此外,受限于试验样本的数量,全局经验模型参数的调整缺少更多全局退化趋势相似的轴承离线观测数据,而目前在实际应用中难以获取。今后如何根据有限的测量数据获取该参数信息,是寿命预测研究中需要重点考虑的问题之一。

参考文献:

- [1] 李巍华,李静,张绍辉.连续隐半马尔科夫模型在轴承性能退化评估中的应用[J].振动工程学报,2014,27(4):613-620.
LI Weihua, LI Jing, ZHANG Shaohui. Application of continuous hidden semi-Markov model in bearing performance degradation assessment[J]. Journal of Vibration Engineering, 2014, 27(4): 613-620.
- [2] 许迪,葛江华,王亚萍,等.流形学习和M-KH-SVR的滚动轴承衰退预测[J].振动工程学报,2018,31(5):892-901.
XU Di, GE Jianghua, WANG Yaping, et al. Prediction for rolling bearing performance degradation based on manifold learning and M-KH-SVR[J]. Journal of Vibration Engineering, 2018, 31(5): 892-901.
- [3] 周建民,尹文豪,游涛,等.结合DSHDD和模糊评价的滚动轴承退化状态在线识别[J].振动工程学报,2021,34(3):646-653.
ZHOU Jianmin, YIN Wenhao, YOU Tao, et al. Online identification of rolling bearing degradation state based on DSHDD and fuzzy evaluation[J]. Journal of Vibration Engineering, 2021, 34(3): 646-653.
- [4] Zhang Z, Huang W, Liao Y, et al. Bearing fault diagnosis via generalized logarithm sparse regularization[J]. Mechanical Systems and Signal Processing, 2022, 167: 108576.
- [5] Chen Z, Xia T, Li Y, et al. A hybrid prognostic method based on gated recurrent unit network and an adaptive Wiener process model considering measurement errors[J]. Mechanical Systems and Signal Processing, 2021, 158: 107785.
- [6] Niu G, Yang B. Intelligent condition monitoring and

- prognostics system based on data-fusion strategy[J]. *Expert Systems with Applications*, 2010, 37(12): 8831-8840
- [7] 申彦斌,张小丽,夏勇,等. Bi-LSTM神经网络用于轴承剩余使用寿命预测研究[J]. *振动工程学报*, 2021, 34(2): 411-420.
- SHEN Yanbin, ZHANG Xiaoli, XIA Yong, et al. Bi-LSTM neural network for remaining useful life prediction of bearings[J]. *Journal of Vibration Engineering*, 2021, 34(2): 411-420.
- [8] Hong S, Zhou Z, Zio E, et al. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method[J]. *Digital Signal Processing*, 2014, 27: 159-166.
- [9] Wang B, Lei Y, Yan T, et al. Recurrent convolutional neural network: a new framework for remaining useful life prediction of machinery[J]. *Neurocomputing*, 2020, 379: 117-129.
- [10] Zhao R, Yan R, Chen Z, et al. Deep learning and its applications to machine health monitoring[J]. *Mechanical Systems and Signal Processing*, 2019, 115: 213-237.
- [11] Wang D, Tsui K L. Two novel mixed effects models for prognostics of rolling element bearings[J]. *Mechanical Systems and Signal Processing*, 2018, 99: 1-13.
- [12] 文娟,高宏力. 一种基于UPF的轴承剩余寿命预测方法[J]. *振动与冲击*, 2018, 37(24): 208-213.
- WEN Juan, GAO Hongli. Remaining useful life prediction of bearings with the unscented particle filter approach[J]. *Journal of Vibration and Shock*, 2018, 37(24): 208-213.
- [13] 严刚,汤剑飞. 基于粒子滤波的疲劳裂纹扩展和剩余寿命预测实验研究[J]. *实验力学*, 2019, 34(5): 775-782.
- YAN Gang, TANG Jianfei. Experimental study on prediction of fatigue crack growth and residual life by using particle filter[J]. *Journal of Experimental Mechanics*, 2019, 34(5): 775-782.
- [14] 张云超. 旋转机械剩余寿命预测方法研究[D]. 南京: 南京航空航天大学, 2020.
- ZHANG Yunchao. Research on remain useful lifetime prediction method of rotating machinery[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020.
- [15] Chen J, Yuan S, Jin X. On-line prognosis of fatigue cracking via a regularized particle filter and guided wave monitoring[J]. *Mechanical Systems and Signal Processing*, 2019, 131: 1-17.
- [16] 马彦,陈阳,张帆,等. 基于扩展 H_∞ 粒子滤波算法的动力电池寿命预测方法[J]. *机械工程学报*, 2019, 55(20): 36-43.
- MA Yan, CHEN Yang, ZHANG Fan, et al. Remaining useful life prediction of power battery based on extended H_∞ particle filter algorithm[J]. *Journal of Mechanical Engineering*, 2019, 55(20): 36-43.
- [17] El-Thalji I, Jantunen E. A descriptive model of wear evolution in rolling bearings[J]. *Engineering Failure Analysis*, 2014, 45: 204-224.
- [18] Jouin M, Gouriveau R, Hissel D, et al. Particle filter-based prognostics: review, discussion and perspectives[J]. *Mechanical Systems and Signal Processing*, 2016, 72-73: 2-31.
- [19] Wang B, Lei Y, Li N, 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.

A remaining life prediction method for rolling bearing based on frequency domain correlation analysis and improved particle filter

LIANG Jie-lin¹, DING Kang¹, HE Guo-lin^{1,2}, LIN Hui-bin¹, JIANG Fei¹

(1. School of Mechanical & Automotive Engineering, South China University of Technology, Guangzhou 510640, China;

2. Pazhou Lab, Guangzhou 510335, China)

Abstract: Aiming at two key problems of the difficulty in identifying the degraded state and the large remaining useful life (RUL) prediction error of rolling bearings, a method combined frequency domain correlation analysis with improved particle filter is proposed to address these problems. Based on the characteristic of short-term similarity and long-term difference of bearing vibration signal in frequency domain during the degradation process, the average correlation coefficient (ACC) curve is constructed by the correlation analysis of the amplitude spectrum in frequency domain. When the ACC reaches the preset threshold, the initial failure time (Degradation Initial Timepoint, DIT) is utilized to divide the bearing state into normal and damage stages. Then, the root mean square (RMS) values of vibration signals in damage stage is adopted as the input of observation samples. The dual factor particle filter (DFPF) model, which considers both global exponential degradation tendency and local fluctuation of the measurements, is constructed to correct the particle distribution and predict RUL of bearings. The experimental results show that the proposed method can effectively identify the accurate initial failure time of bearings than traditional RMS and kurtosis method. Moreover, compared with the conventional particle filter (PF) algorithm, the proposed method reduces the interference of abnormal observations on the prediction trend and has higher RUL prediction accuracy.

Key words: remaining useful life prediction; rolling bearings; frequency domain correlation analysis; state division; particle filter

作者简介: 梁洁琳(1996—),女,硕士研究生。E-mail: 610834756@qq.com。

通讯作者: 何国林(1986—),男,博士,副教授。E-mail: hegl@scut.edu.cn。