

文章编号: 1006-3080(2025)05-0722-09

DOI: 10.14135/j.cnki.1006-3080.20241211001

基于含工况影响维纳过程模型的剩余寿命预测方法

顾昊言¹, 李 勇¹, 狄广强², 周心洁², 温建锋¹

(1. 华东理工大学机械与动力工程学院, 上海 200237; 2. 中国联合重型燃气轮机技术有限公司, 上海 201306)

摘要: 机械设备运行工况的变化不仅更容易诱发零部件性能退化, 还会影响退化过程的稳定性, 为零部件的剩余寿命预测带来了挑战。针对工况因素对机械设备退化的影响, 本文提出一种含工况影响的维纳过程模型, 通过引入幂律形式的工况相关项捕捉退化过程与工况之间的关系, 并采用单元极大似然估计算法估计模型参数; 然后, 采用卡尔曼-粒子滤波算法更新单元可变参数; 根据构建的模型, 推导剩余寿命概率密度函数的解析表达式。最后, 利用合金和轴承退化数据集进行实验验证。结果表明, 所提出模型在两种数据集中的赤池信息准则为-185.64和-537.76, 优于传统模型; 所提出预测方法在两种数据集中的平均累积相对精度为0.93和0.86, 平均总体均方误差为25.74和28.34, 均优于基于粒子滤波和基于贝叶斯原理的预测方法。

关键词: 剩余寿命预测; 维纳过程模型; 运行工况; 集成卡尔曼滤波; 粒子滤波

中图分类号: O213.2

文献标志码: A

预测性维护技术是确保在役机械设备安全、可靠运行的有效手段, 已被广泛应用于航空航天、军事国防、能源石化等诸多工业领域。它的核心目标是通过设备健康状态的精准监测和评估, 提前发现潜在的故障并采取预防措施, 从而有效地降低故障发生率。剩余寿命 (Remaining Useful Life, RUL) 预测是预测性维护的前提, 通过对机械设备 (或关键部件) RUL 的准确预测, 不仅能够提前预警设备面临的潜在风险, 还能有效指导维护策略制定与预防维护措施实施^[1-2]。随着传感技术的不断进步, 现代设备监测系统能够准确捕捉设备运行过程中各项关键参数的变化, 并提供实时的健康状态反馈。基于监测数据, 通过拟合设备健康状态的演化规律并外推到失效阈值以实现 RUL 预测, 成为一种可行的技术思路^[3]。在工业实际中, 由于受工作环境、材料内部特性和个体差异等因素影响, 设备的退化通常表现为典型的随机变化过程。随机过程模型因其在捕捉机械设

备退化过程随机动力学特征方面的显著优势, 成为常用的预测模型之一。在这类模型中, 维纳过程模型 (Wiener Process Model, WPM) 非常适合于拟合非单调的退化过程, 且具备明确的物理意义和优异的数学特性, 因此应用最为广泛^[4]。

传统的 WPM 由漂移项和扩散项两部分组成, 其中漂移项表示设备整体的退化趋势, 扩散项反映了环境中的不确定因素对退化过程的影响。这类模型假设漂移项系数和扩散项系数均为常数, 因此, 只能描述相同服役环境下的线性退化过程, 限制了模型的实际应用^[5]。通常, 设备的退化过程存在多源的不确定性。Yu 等^[6]总结了 3 种主要的影响来源, 包括时间尺度上的可变性、个体单元之间的可变性和测量结果的不确定性。在工程实践中, 设备的工况会由于外部环境和内部状态的变化而改变, 这种动态工况往往会引入额外的不确定性^[7]。例如, 随着应力水平的提高, 疲劳裂纹的扩展速度也会增加^[8]。当

收稿日期: 2024-12-11

基金项目: 上海市探索者计划 (24TS1411900)

作者简介: 顾昊言 (1999—), 男, 江苏靖江人, 硕士生, 主要研究方向为故障预测与健康管理。E-mail: Y30210602@mail.ecust.edu.cn

通信联系人: 李 勇, E-mail: liyong@ecust.edu.cn

引用本文: 顾昊言, 李 勇, 狄广强, 等. 基于含工况影响维纳过程模型的剩余寿命预测方法 [J]. 华东理工大学学报 (自然科学版), 2025, 51(5): 722-730.

Citation: GU Haoyan, LI Yong, DI Guangqiang, et al. Remaining Useful Life Prediction Method Based on the Wiener Process Model with Condition Influence[J]. Journal of East China University of Science and Technology, 2025, 51(5): 722-730.

存在多种工况时,传统的 WPM 无法准确描述设备的退化过程,从而影响 RUL 预测的准确性。Lin 等^[9]利用多阶段模型来描述外部工况存在变化的退化过程,但是每个阶段中的工况被认为是稳定的。在近些年的研究中,为了适应时变的工况条件,工况通常被作为协变量引入模型。Li 等^[10]通过引入工况系数,并与退化速率相乘以描述工况对退化过程的影响。Xu 等^[11]用 Arrhenius 模型表示温度对锂电池退化速率的影响,并将其引入非线性维纳过程,构建出了锂电池的退化模型。基于 Arrhenius 模型, Guan 等^[12]构建了一种线性函数用于反映退化速率和工况之间的关系,并利用不同转速和载荷下的轴承退化数据验证了模型的有效性。Zhang 等^[13]采用 Ornstein-Uhlenbeck 过程对工况进行建模,并与退化速率关联,从而使得模型能够反映实际工况的波动性。考虑到退化速率与退化过程波动性之间的关联, Wang 等^[14]进一步建立了漂移系数和扩散系数之间的定量关系,以反映两者对工况的联合依赖性。然而,该关系仅适用于线性的 WPM。此外,在考虑单元间可变性时,退化速率通常被假设为服从正态分布的随机变量^[15]。尽管引入工况相关项不会改变其分布性质,但不同单元的实际退化速率可能并不符合正态分布^[16]。因此,基于正态分布的模型训练方法可能导致参数更新结果出现误差^[17]。

由文献分析可见,现有方法在预测过程中未充分考虑时间尺度的可变性以及动态工况对单元可变性的影响。不同工况对机械设备退化过程的影响程度不同,工况与退化过程之间的关系需要从真实的退化数据中捕捉。为了解决这些问题,本文提出一种通用的幂律模型对工况的影响进行建模,并引入单元可变参数,以区分设备个体间的差异性和工况的影响;考虑到不同工况对模型参数的影响,引入了卡尔曼-粒子滤波的模型参数更新方法。其中,集成卡尔曼滤波用于调整参数的先验分布,粒子滤波算法用于更新后验估计;基于所提出的模型,推导出了 RUL 概率密度函数的解析形式。

1 RUL 预测方法

1.1 预测模型构建

现有年龄的相关 WPM 可以表示为:

$$x(t) = x(t_k) + \int_{t_k}^t \mu(\tau) d\tau + \int_{t_k}^t \sigma_B dB(\tau) \quad (1)$$

其中, $x(t)$ 是设备在 $t(t \geq t_k)$ 时刻的健康状态指标,用于反映设备退化的严重程度,如疲劳裂纹长度、刀具

磨损量和振动水平大小等^[18-20]; t_k 是退化的起始时刻; $\mu(\tau)$ 是漂移系数函数,表示退化速率; σ_B 是扩散项系数,表示退化过程的波动性; $B(\tau)$ 表示一个标准的布朗运动。

式 (1) 描述的退化过程仅与设备的年龄相关,因此只适用于单一工况的情况。由于模型中的固定参数不会响应工况的变化,因此当工况改变时,模型的拟合效果将会下降。尽管关于工况影响的物理模型已经得到广泛研究,但由于模型内部参数难以在线获取,因此不适合直接应用于基于监测数据进行预测的方法。然而,物理模型所揭示的映射关系却被广泛采用^[21-22]。考虑到不同工况与退化速率之间复杂的非线性关系,为提高模型的通用性,本文采用幂律模型对工况的影响程度进行建模。工况影响模型表示为:

$$\Lambda(\gamma) = (c\gamma - d)^e \quad (2)$$

其中, γ 表示对退化过程起主要影响的运行工况,如载荷、转速、温度等; c 、 d 、 e 为固定参数,由不同工况下的退化数据训练得到。

当设备的操作设置改变时,可能会对多个工况造成影响。为简化复杂工况的影响,本文引入主成分分析,提取贡献最高的主成分作为对退化过程影响较大的主要工况。假设存在 Q 个运行工况 $\{\gamma_q\}_{q=1}^Q$, 在不同样本中表示为 $\{\gamma_{1,q}, \dots, \gamma_{m,q}, \dots, \gamma_{M,q}\}_{q=1}^Q$, 其中 M 为样本的个数。主要工况的构建步骤如下:

(1) 对工况参数进行标准化处理:

$$z_{m,q} = \frac{\gamma_{m,q} - \mu_q}{\sqrt{\sigma_q^2}} \quad (3)$$

其中, $z_{m,q}$ 表示标准化后的工况; $\mu_q = \frac{1}{M} \sum_{m=1}^M \gamma_{m,q}$;

$$\sigma_q^2 = \frac{1}{M-1} \sum_{m=1}^M (\gamma_{m,q} - \mu_q)^2。$$

(2) 计算相关系数 $r_{i,j} = \frac{1}{M-1} \sum_{p=1}^M z_{p,i} * z_{p,j}$ ($i, j = 1, 2, \dots, Q$), 得到协方差矩阵 R :

$$R = \begin{bmatrix} r_{1,1} & r_{1,2} & \dots & r_{1,Q} \\ r_{2,1} & r_{2,2} & \dots & r_{2,Q} \\ \vdots & \vdots & \ddots & \vdots \\ r_{Q,1} & r_{Q,2} & \dots & r_{Q,Q} \end{bmatrix} \quad (4)$$

(3) 计算协方差矩阵 R 的特征值和对应的特征向量。将贡献率最高的主成分作为主要工况, 即 $\hat{\gamma} = [\gamma_1, \gamma_2, \dots, \gamma_Q] * \hat{\rho}$, 其中 $\hat{\rho}$ 为最大特征值对应的特征向量。

在实际工程中,受制造、装配过程中不确定因素的影响,即使在相同工况条件下,同类设备不同个体之间的退化过程也会表现出差异性。现有研究通常

在模型的漂移项中引入随机参数来描述这样的不确定性,如 $\mu(\tau)=\alpha\varphi(\tau)$,其中,一般假设 α 服从正态分布以便于计算。然而,设备不同的服役工况也会影响随机参数的分布,此时假设其遵循特定的分布已不再合理。为了区分单元间差异和工况的影响,本文在模型中引入单元可变参数。在模型训练时,每个训练样本对应一个单元可变参数,从而避免特定分布的限制。为解决工况对退化过程的影响,进一步将式(2)引入到模型中的固定参数中,得到改进WPM的一般表达式如下:

$$x(t) = x(t_k) + a \int_{t_k}^t \varphi(\tau, \Lambda(\gamma)) d\tau + \int_{t_k}^t \sigma_B \sqrt{\Lambda(\gamma)} dB(\tau) \quad (5)$$

其中, a 是单元可变参数,用于描述不同个体之间的差异性; $\varphi(\tau, \Lambda(\gamma))$ 表示平均退化速率函数。

1.2 参数估计

在模型训练时,首先使用历史退化数据初步估计模型中的未知参数。假设 $\{x_m\}_{m=1}^M$ 表示用于训练模型的样本数据集,其中 M 为样本个数。每个训练样本由一系列观测点组成,即 $\mathbf{x}_m = [x_m(t_{m,1}), x_m(t_{m,2}), \dots, x_m(t_{m,n}), \dots, x_m(t_{m,N_m})]^T$,其中 N_m 为第 m 个样本中观测点的个数。为简洁起见,将 $x_m(t_{m,n})$ 记为 $x_{m,n}$ 。由于观测数据是离散的,所以使用欧拉离散方法获得式(5)的离散表达式:

$$x_{m,N_m} = x_{m,1} + a_m \sum_{n=1}^{N_m-1} T_{m,n}(\Lambda(\gamma_m)) + \sum_{n=1}^{N_m-1} \sigma_B \sqrt{\Lambda(\gamma_m)} B(\Delta t_{m,n}) \quad (6)$$

其中,

$$T_{m,n}(\Lambda(\gamma_m)) = \int_{t_{m,n}}^{t_{m,n+1}} \varphi(\tau, \Lambda(\gamma_m)) d\tau \quad (7)$$

$$\Delta t_{m,n} = t_{m,n+1} - t_{m,n} \quad (8)$$

令 $\Delta \mathbf{x}_m = [x_{m,2} - x_{m,1}, \dots, x_{m,N_m} - x_{m,N_m-1}]^T$ 表示两个相邻观测值之间的增量向量。根据维纳过程的性质可知, $\Delta \mathbf{x}_m$ 服从多元正态分布 $N(a_m \mathbf{T}_m, \sigma_B^2 \boldsymbol{\Sigma}_m)$,其中

$$\mathbf{T}_m = [T_{m,1}(\Lambda(\gamma_m)), \dots, T_{m,N_m-1}(\Lambda(\gamma_m))]^T \quad (9)$$

$$\boldsymbol{\Sigma}_m = \Lambda(\gamma_m) \text{diag}([\Delta t_{m,1}, \dots, \Delta t_{m,N_m-1}]) \quad (10)$$

式中, $\text{diag}([\Delta t_{m,1}, \dots, \Delta t_{m,N_m-1}])$ 表示一个对角线元素为 $[\Delta t_{m,1}, \dots, \Delta t_{m,N_m-1}]$ 的对角矩阵。

令 $\mathbf{X} = \{\Delta x_1, \Delta x_2, \dots, \Delta x_M\}$ 表示所有训练样本的增量向量数据,则 $\mathbf{X}$ 的对数似然函数可以表示为:

$$\ln L(\mathbf{X}) = -\frac{\ln(2\pi\sigma_B^2)}{2} \sum_{m=1}^M (N_m - 1) - \frac{1}{2} \sum_{m=1}^M \ln |\boldsymbol{\Sigma}_m| - \frac{1}{2\sigma_B^2} \sum_{m=1}^M (\Delta \mathbf{x}_m - a_m \mathbf{T}_m)^T \boldsymbol{\Sigma}_m^{-1} (\Delta \mathbf{x}_m - a_m \mathbf{T}_m) \quad (11)$$

式中, a_m 和 σ_B^2 可通过计算偏导数方程得到,即令 $\ln L(\mathbf{X})$ 关于 a_m 和 σ_B^2 的一阶偏导数为0,估计结果可表示为:

$$\hat{a}_m = (\mathbf{T}_m^T \boldsymbol{\Sigma}_m^{-1} \Delta \mathbf{x}_m) / (\mathbf{T}_m^T \boldsymbol{\Sigma}_m^{-1} \mathbf{T}_m) \quad (12)$$

$$\hat{\sigma}_B^2 = \frac{\sum_{m=1}^M (\Delta \mathbf{x}_m - \hat{a}_m \mathbf{T}_m)^T \boldsymbol{\Sigma}_m^{-1} (\Delta \mathbf{x}_m - \hat{a}_m \mathbf{T}_m)}{\sum_{m=1}^M (N_m - 1)} \quad (13)$$

将式(12)和式(13)代入式(11),简化后的表达式如下:

$$\ln L(\mathbf{X}) = -\frac{\ln(2\pi\hat{\sigma}_B^2) + 1}{2} \sum_{m=1}^M (N_m - 1) - \frac{1}{2} \sum_{m=1}^M \ln |\boldsymbol{\Sigma}_m| \quad (14)$$

由于剩余的未知参数难以计算其显式表达式,因此使用多维优化算法最大化式(14)进行估计,例如MATLAB中的“FMINSEARCH”函数^[23],其原理是基于Nelder-Mead算法寻找多元函数的最小值,通常用于参数导数未知的情况。由于该算法的估计结果对初值比较敏感,因此需要随机生成多个初值进行重复搜索,以获得最佳结果。

1.3 参数更新

利用历史数据的离线训练能够为单元可变参数提供一个初始分布。为了提升模型的预测精度,对于在线运行的设备,通常需要使用实时退化数据更新模型中的单元可变参数,使其能够准确地反映当前设备的退化情况。粒子滤波算法在处理非正态分布的状态估计问题时具有显著优势,且通过参数估计得到的单元可变参数可以直接用作先验数据^[24]。由于参数的先验分布可能受到不同运行工况的影响,标准粒子滤波算法在应用中容易出现粒子退化问题^[25],这意味着只有小部分粒子会在更新中起作用。针对这个问题,本文引入一种卡尔曼-粒子滤波算法对单元可变参数进行更新^[26]。首先,根据观测值使用集成卡尔曼滤波将所有粒子转移到更靠近观测值的位置,再使用粒子滤波算法获得单元可变参数的后验估计。该算法的流程如图1所示,具体步骤如下:

(1) 首次更新时,将训练样本的单元可变参数估计结果作为初始粒子集 $\{a_{i,0}\}_{i=1}^M$ 。假设所有粒子的权重相同,即 $\omega_{i,0} = 1/M$ 。

(2) 根据历史粒子,构建预测粒子如下:

$$a_{i,k}^f = a_{i,k-1} (i = 1, 2, \dots, M) \quad (15)$$

式中, k 表示算法迭代的次数; $a_{i,k}^f$ 是第 i 个粒子在第




图 1 参数更新算法流程图

Fig. 1 Flowchart of the parameter update algorithm

k 次迭代中的预测值; $a_{i,k-1}$ 是第 i 个粒子在第 $k-1$ 次迭代后的更新值。

(3) 计算卡尔曼增益:

$$K_k = P_k^f H^T (H P_k^f H^T + \varepsilon_k)^{-1} \quad (16)$$

其中, $\varepsilon_k \sim N(0, \sigma_B^2 \Lambda(\gamma) \Delta t_k)$ 。

$$P_k^f H^T = \frac{1}{M-1} \sum_{i=1}^M (a_{i,k}^f - \bar{a}_k^f) (T_k a_{i,k}^f - T_k \bar{a}_k^f) \quad (17)$$

$$H P_k^f H^T = \frac{1}{M-1} \sum_{i=1}^M (T_k a_{i,k}^f - T_k \bar{a}_k^f)^2 \quad (18)$$

其中, $\bar{a}_k^f = \sum_{i=1}^M a_{i,k}^f / M$ 表示预测粒子的平均值。

(4) 根据新的观测值更新每个粒子, 计算方法如下:

$$a_{i,k} = a_{i,k}^f + K_k (\Delta x_k - T_k a_{i,k}^f + \varepsilon_k) \quad (19)$$

其中, $\Delta x_k = x_k - x_{k-1}$, 表示在线设备从 t_{k-1} 至 t_k 的退化量。

(5) 初始化步骤 (4) 中生成粒子的权重, 即 $\omega_{i,k} = 1/M$ 。根据新的观测值, 更新每个粒子在第 k 次迭代中的权重:

$$\begin{aligned} \omega_{i,k}^* &= \omega_{i,k} \frac{1}{\sqrt{2\pi\sigma_B^2\Lambda(\gamma)\Delta t_k}} \exp\left(-\frac{(\Delta x_k - T_k a_{i,k}^f)^2}{2\sigma_B^2\Lambda(\gamma)\Delta t_k}\right) \\ \hat{\omega}_{i,k} &= \omega_{i,k}^* / \sum_{i=1}^M \omega_{i,k}^* \end{aligned} \quad (20)$$

(6) 计算有效粒子的个数 N_{eff} 。如果 N_{eff} 小于一个预先设置的阈值 N_T , 则对所有粒子进行模糊重采

样^[16]。否则, 直接执行下一步。 N_{eff} 的计算方式为:

$$N_{\text{eff}} = 1 / \sum_{i=1}^M (\hat{\omega}_{i,k})^2 \quad (21)$$

(7) 第 k 次迭代最终的更新结果可以表示为:

$$\hat{a}_k = \sum_{i=1}^M \hat{\omega}_{i,k} a_{i,k} \quad (22)$$

每当出现新的观测值时, 重复步骤 (2)~(7) 更新单元可变参数, 从而使得模型能够反映设备最新的退化趋势。

1.4 RUL 估计

设备的 RUL 通常被定义为其健康状态的退化首次超过失效阈值的时间。根据定义, 设备在 t_k 时刻的 RUL 可以表示为:

$$l_k = \inf\{l : x(t_k + l) \geq \lambda | x(t_k) < \lambda\} \quad (23)$$

其中, $\inf\{\cdot\}$ 表示一个变量的下界; λ 是失效阈值。

对于如式 (5) 所示的退化过程 $x(t)$, $t \geq t_k$, 其在固定失效阈值 λ 条件下, t_k 时刻的 RUL 概率密度函数的解析表达式为:

$$\begin{aligned} f(l) &\cong \left(\lambda - x_k - a \int_0^l \varphi(\tau + t_k, \Lambda(\gamma)) d\tau + \right. \\ &\quad \left. a\varphi(l + t_k, \Lambda(\gamma))l \right) \times \frac{1}{\sqrt{2\pi\sigma_B^2\Lambda(\gamma)l^3}} \times \\ &\quad \exp\left(-\frac{(\lambda - x_k - a \int_0^l \varphi(\tau + t_k, \Lambda(\gamma)) d\tau)^2}{2\sigma_B^2\Lambda(\gamma)l}\right) \end{aligned} \quad (24)$$

将参数估计和更新结果以及设备在未来的运行

工况代入式 (24), 即可得到 RUL 的概率密度函数 (PDF)。它能够揭示设备在不同时刻的失效概率, 为维护策略的制定提供了理论依据。

2 实验验证

为了验证论文提出方法的有效性, 本节利用 2024-T62 铝合金疲劳裂纹扩展数据集进行实验验证^[27]。在本数据集中, 21 个合金试件被平均分为 3 组, 分别在 120、135 MPa 和 150 MPa 应力水平下进行疲劳裂纹扩展实验。每 9000 次循环记录一次裂纹尺寸, 如图 2 所示。由于该实验并未设置用于停止实验的裂纹阈值, 因此将第 90000 次循环时的观测值作为失效阈值。将应力 120 MPa 下的一个试件选为测试样本, 其余样本用于模型训练。




图 2 2024-T62 铝合金疲劳裂纹扩展数据

Fig. 2 Fatigue crack propagation data of 2024-T62 aluminum

从图 2 中可以看出, 应力对退化过程的影响是显著的。随着应力水平的增加, 退化速率和退化过程中的不确定性都会增加。因此, 将应力水平作为主要工况, 并建立预测模型如下:

$$x(t) = x(t_k) + a \int_{t_k}^t b \Lambda(\gamma) \exp(b \Lambda(\gamma) \tau) d\tau + \int_{t_k}^t \sigma_B \sqrt{\Lambda(\gamma)} dB(\tau) \quad (25)$$

其中, γ 表示应力水平; b 、 σ_B 是固定参数。

使用训练样本集的退化数据对模型 (25) 中的参数进行估计。图 3 所示为单元可变参数 a 的估计结果, 由图 3 可知, 不同应力水平对应 a 的取值范围有着明显的边界, 这表明应力对单元可变参数的估计结果有一定的影响。因此, 为了减少参数更新过程中粒子退化的问题, 采用卡尔曼-粒子滤波算法进行参数更新。图 4 所示为测试样本中参数 a 的更新过程, 可以看出, 随着迭代次数的增加, 更新结果的均值越来越接近真实值。同时, 所有粒子向着真实值

所在的区域收敛, 有效地降低了粒子退化的影响。




图 3 单元可变参数估计结果

Fig. 3 Estimation results of the unit variability parameter




图 4 单元可变参数更新结果

Fig. 4 Update results of the unit variability parameter

为验证上述模型的有效性, 分别使用含有工况影响 $\Lambda(\gamma)$ 的模型 (25) 和传统不含 $\Lambda(\gamma)$ 的模型对训练样本进行拟合。此外, 为进一步验证所提出工况影响模型的性能, 引入幂律模型 $\eta(\gamma) = \exp(c + d\gamma)$ ^[21] 和指数模型 $\psi(\gamma) = c\gamma^d$ ^[22] 进行对比分析。采用赤池信息准则 (Akaike Information Criterion, AIC) 来表示模型的拟合效果, AIC 的取值越低表明模型的拟合效果越好^[28]。表 1 给出了不同模型的参数估计结果, 其中“—”表示模型中未包含的参数, c 、 d 、 e 是固定参数。从表 1 中可以看出, 与传统 WPM 相比, 所提出模型的 AIC 较小, 其拟合性能相较于传统 WPM 提升约 39.9%; 与其他工况影响模型相比, 拟合性能相近。图 5 展示了两种不同模型的 RUL 预测效果, 可以看出, 随着参数的更新, 两种模型的 RUL 预测结果均逐渐接近真实的 RUL, 且结果的不确定性不断减小, 表明本文所提出的参数更新策略是有效的。然而, 与传统 WPM 相比, 所提出模型的预测结果明显更加精确。图 6 示出了两种不同模型的模拟退化路径, 分析可知, 由于存在退化过程呈非线性的训练样本, 导致传统 WPM 的训练结果趋于非线性。然而, 测试样本的退化过程趋于线性, 传统 WPM 模拟的退化路径将提前超过失效阈值, 这使得 RUL 的预测结

表 1 裂纹扩展数据集的参数估计结果

Table 1 Parameter estimation results of fatigue crack propagation dataset

Model	σ_b^2	b	c	d	e	$\ln L(X)$	AIC
WPM with $\Lambda(\gamma)$	3.74×10^{-7}	3.17×10^{-6}	3.43×10^{-2}	-1.61	4.79	98.82	-185.64
Traditional WPM	3.30×10^{-3}	2.48×10^{-2}	—	—	—	69.35	-132.70
WPM with $\eta(\gamma)$	2.98×10^{-6}	3.13	3.94	2.53×10^{-5}	—	98.96	-187.92
WPM with $\psi(\gamma)$	7.75×10^{-9}	1.27	2.55	6.32×10^{-8}	—	96.16	-182.32




图 5 合金测试样本的 RUL 预测结果: (a) 含有 $\Lambda(\gamma)$ 的维纳过程模型; (b) 传统维纳过程模型
Fig. 5 RUL prediction results of the alloy test specimen: (a)WPM with $\Lambda(\gamma)$; (b)Traditional WPM

果普遍偏小。相比之下,所提出的模型可以根据工况进一步调整参数,从而更好地模拟不同应力水平下的退化路径。因此,含工况影响 WPM 的预测结果更为准确。




图 6 两种不同模型的模拟退化路径
Fig. 6 Simulated degradation paths of two different models

为了进一步验证所提出预测方法的优越性,给出了两种常用的方法作为对照。为方便起见,将所提出的预测方法记为 M1,将基于粒子滤波和贝叶斯原理的预测方法分别记为 M2 和 M3。由 M1、M2 和 M3 得到的平均 RUL 预测结果和标准差 (Standard Deviation, SD) 范围如图 7 所示,可以看出 M1 的结果更接近真实的 RUL。

为了量化预测精度,引入累积相对精度 (Cumulative Relative Accuracy, CRA) 和总体均方误




图 7 合金测试样本的 RUL 预测结果
Fig. 7 RUL prediction results of the alloy test specimen

差 (Total Mean Square Error, TMSE) 指标进行评价,计算方法如下:

$$CRA = \frac{1}{N-1} \sum_{k=2}^N \left(1 - \frac{|l_k - l_{\text{real}} + t_k|}{l_{\text{real}} - t_k} \right) \quad (26)$$

$$TMSE = \frac{1}{N-1} \sum_{k=2}^N \int_0^{\infty} (l_k - l_{\text{real}} + t_k)^2 f(l_k) dl_k \quad (27)$$

其中, N 是测试样本的观测点数; l_k 表示测试样本在 t_k 时刻的 RUL; l_{real} 是测试样本真实的寿命。

CRA 取值越大或 TMSE 取值越小,表明预测精度越高。不同预测方法在多次实验中的平均 CRA 和 TMSE 如表 2 所示,可以看出 M1 在合金测试样本中取得了更准确的预测结果,其 CRA 和 TMSE 相较于其他方法提升约 4.5% 和 52.5%。

表 2 不同预测方法的平均预测精度

Table 2 Average prediction accuracies of the different prediction methods

Method	Alloy test specimen		Bearing test specimen	
	CRA	TMSE	CRA	TMSE
M1	0.93	25.74	0.86	28.34
M2	0.87	54.29	0.79	189.98
M3	0.89	54.31	0.82	34.02

为了评估所提出模型和方法的通用性,使用 XJTU-SY 轴承数据集进行相同的实验^[29]。从数据集中选择一些不同径向力作用下的试件作为实验对象。将每次采样中振动信号的最大幅值作为轴承的健康指标,轴承的退化数据如图 8 所示。失效阈值使用相对法确定,即当振动信号的最大幅值超过轴承正常运行阶段幅值的 10 倍时,视为轴承已经失效。将径向力 12 kN 作用下的一个试件选为测试样本,其余试件作为训练样本。

表 3 给出了不同模型的参数估计结果,可以看出,与传统 WPM 相比,所提出模型的 AIC 较小,其拟合性能提升约 8.6%;与其他工况影响模型相比,所提




图 8 轴承退化数据



Fig. 8 Bearing degradation data

出工况影响模型的拟合性能有明显的提升。图 9 示出了两种不同模型对于轴承测试样本的 RUL 预测结果,可以看出,所提出的模型同样获得了更准确的预测结果。图 10 示出了分别使用 M1、M2 和 M3 得到的轴承测试样本的 RUL 预测结果,可以看出,与 M2 和 M3 相比, M1 的预测结果更符合真实的 RUL。从表 2 中可以看出, M1 在轴承测试样本中的 CRA 和 TMSE 相较于其他方法提升约 4.9% 和 16.7%,表明本文提出的方法具有更好的预测性能。

表 3 轴承数据集的参数估计结果

Table 3 Parameter estimation results of the bearing dataset

Model	σ_B^2	b	c	d	e	$\ln L(X)$	AIC
WPM with $\Lambda(\gamma)$	4.60×10^{-3}	3.04×10^{-3}	0.10	-0.72	3.56	274.88	-537.76
Traditional WPM	0.04	2.59×10^{-2}	—	—	—	250.53	-495.06
WPM with $\eta(\gamma)$	7.75×10^{-9}	0.99	1.30	2.98×10^{-3}	—	265.94	-521.88
WPM with $\psi(\gamma)$	0.35	6.76×10^{-2}	0.24	0.23	—	253.84	-497.68

图 9 轴承测试样本的 RUL 预测结果: 含有 $\Lambda(\gamma)$ 的维纳过程模型 (a); 传统维纳过程模型 (b)Fig. 9 RUL prediction results of the bearing test specimen: WPM with $\Lambda(\gamma)$ (a); Traditional WPM (b)




图10 轴承测试样本的RUL预测结果

Fig. 10 RUL prediction results of the bearing test specimen

3 结束语

工况是影响机械设备退化过程的关键因素。针对变工况下设备的RUL预测,本文提出了一种基于含工况影响WPM的预测方法。相较于传统基于WPM的预测方法,本文所提出的模型和方法在不同工况条件下具有更高的预测准确性。针对RUL预测中工况的影响,本研究重点分析了对退化过程影响显著的主要工况,而工况的多样性和复杂性仍然是值得进一步考虑的因素。在未来的工作中,量化多源工况耦合的影响将成为一个提高RUL预测准确性的重要研究方向。

参考文献:

- [1] ZIO E. Prognostics and Health Management (PHM): Where are we and where do we (need to) go in theory and practice[J]. *Reliability Engineering & System Safety*, 2022, 218: 108119.
- [2] 韩少鹏,陆宁云,姜斌. 基于不确定信息的系统建模与状态预测方法[J]. *华东理工大学学报(自然科学版)*, 2013, 39(1): 77-82.
- [3] 李乃鹏,蔡潇,雷亚国,等. 一种融合多传感器数据的数模联动机械剩余寿命预测方法[J]. *机械工程学报*, 2021, 57(20): 29-37.
- [4] SI X S, WANG W, 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.
- [5] ZHANG Z, SI X, HU C, *et al.* Degradation data analysis and remaining useful life estimation: A review on Wiener-process-based methods[J]. *European Journal of Operational Research*, 2018, 271(3): 775-796.
- [6] YU W, TU W, KIM I Y, *et al.* A nonlinear-drift-driven Wiener process model for remaining useful life estimation considering three sources of variability[J]. *Reliability Engineering & System Safety*, 2021, 212: 107631.
- [7] PARK S H, PARK J, RYOU M H, *et al.* Sensitivity of power of lithium-ion batteries to temperature: A case study using cylindrical-and pouch-type cells[J]. *Journal of Power Sources*, 2020, 465: 228238.
- [8] PARIS P C, ERDOGAN F. A critical analysis of crack propagation laws[J]. *Journal of Basic Engineering*, 1963, 85(4): 528-533.
- [9] LIN J, LIAO G, CHEN M, *et al.* Two-phase degradation modeling and remaining useful life prediction using nonlinear Wiener process[J]. *Computers & Industrial Engineering*, 2021, 160: 107533.
- [10] LI N, GEBRAEEL N, LEI Y, *et al.* Remaining useful life prediction of machinery under time-varying operating conditions based on a two-factor state-space model[J]. *Reliability Engineering and System Safety*, 2019, 186: 88-100.
- [11] XU X, TANG S, YU C, *et al.* Remaining useful life prediction of lithium-ion batteries based on Wiener process under time-varying temperature condition[J]. *Reliability Engineering and System Safety*, 2021, 214: 107675.
- [12] GUAN Q, WEI X, ZHANG H, *et al.* Remaining useful life prediction for degradation processes based on the Wiener process considering parameter dependence[J]. *Quality and Reliability Engineering International*, 2024, 40(3): 1221-1245.
- [13] ZHANG S, ZHAI Q, SHI X, *et al.* A Wiener process model with dynamic covariate for degradation modeling and remaining useful life prediction[J]. *IEEE Transactions on Reliability*, 2023, 72(1): 214-223.
- [14] WANG H, LIAO H, MA X. Remaining useful life prediction considering joint dependency of degradation rate and variation on time-varying operating conditions[J]. *IEEE Transactions on Reliability*, 2020, 70(2): 761-774.
- [15] WANG Z Q, HU C H, WANG W, *et al.* An additive Wiener process-based prognostic model for hybrid deteriorating systems[J]. *IEEE Transactions on Reliability*, 2014, 63(1): 208-222.
- [16] LI N, LEI Y, YAN T, *et al.* A Wiener-process-model-based method for remaining useful life prediction considering unit-to-unit variability[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(3): 2092-2101.
- [17] 王泽洲,陈云翔,蔡忠义,等. 考虑随机失效阈值的设备剩余寿命在线预测[J]. *系统工程与电子技术*, 2019, 41(5): 1162-1168.
- [18] LI N, LEI Y, GUO L, *et al.* Remaining useful life prediction based on a general expression of stochastic process models[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(7): 5709-5718.
- [19] MA Z, ZHAO M, DAI X, *et al.* A hybrid-driven probabilistic state space model for tool wear monitoring[J]. *Mechanical Systems and Signal Processing*, 2023, 200: 110599.
- [20] LI J, WANG Z, LIU X, *et al.* Remaining useful life prediction of rolling bearings using GRU-DeepAR with adaptive failure threshold[J]. *Sensors*, 2023, 23(3): 1144.
- [21] LIU D, WANG S, ZHANG C. Reliability estimation from two types of accelerated testing data based on an artificial neural network supported Wiener process[J]. *Applied Math-*

- ematics and Computation, 2022, 417: 126757.
- [22] PAN Z, BALAKRISHNAN N. Multiple-steps step-stress accelerated degradation modeling based on Wiener and gamma processes[J]. Communications in Statistics-Simulation and Computation, 2010, 39(7): 1384-1402.
- [23] SI X S, WANG W, HU C H, *et al.* Remaining useful life estimation based on a nonlinear diffusion degradation process[J]. IEEE Transactions on Reliability, 2012, 61(1): 50-67.
- [24] XU Y, XU K, WAN J, *et al.* Research on particle filter tracking method based on Kalman filter[C]//2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC). Xi'an, China: IEEE, 2018: 1564-1568.
- [25] 王学武, 闵永, 顾幸生. 基于密度聚类的多目标粒子群优化算法 [J]. 华东理工大学学报 (自然科学版), 2019, 45(3): 449-457.
- [26] BI H, MA J, WANG F. An improved particle filter algorithm based on ensemble Kalman filter and Markov chain Monte Carlo method[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 8(2): 447-459.
- [27] 王绪虎, 王火平, 王东飞, 等. 2024-T62 铝合金疲劳裂纹扩展试验数据的统计分析 [J]. 机械强度, 2019, 41(3): 611-617.
- [28] ZHENG J F, SI X S, HU C H, *et al.* A nonlinear prognostic model for degrading systems with three-source variability[J]. IEEE Transactions on Reliability, 2016, 65(2): 736-750.
- [29] 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.

Remaining Useful Life Prediction Method Based on the Wiener Process Model with Condition Influence

GU Haoyan¹, LI Yong¹, DI Guangqiang², ZHOU Xinjie², WEN Jianfeng¹

(1. School of Mechanical and Power Engineering, East China University of Science and Technology, Shanghai 200237, China; 2. China United Gas Turbine Technology Co. LTD, Shanghai 201306, China)

Abstract: Changes in the operating conditions of mechanical equipment not only increase the likelihood of performance degradation in mechanical components, but also impact the stability of the degradation process. This introduces challenges in predicting the remaining useful life (RUL) of mechanical equipment. Traditional Wiener process models are typically limited to the RUL prediction under a constant operating condition, leading to reduced accuracy in practical engineering scenarios. To address this problem, this paper proposes a Wiener process model that incorporates the influence of operating conditions. An exponential condition-dependent function is introduced to capture the relationship between the degradation process and operating conditions. Model parameters are estimated using the unit maximum likelihood estimation algorithm. Then, the variable parameter within the model is dynamically updated using an ensemble Kalman filter combined with a particle filter. Additionally, an analytical expression for the probability density function of the RUL is derived based on the constructed model. Finally, the effectiveness of the proposed prediction method is validated using a fatigue crack propagation dataset and a bearing degradation dataset. The experimental results show that the Akaike Information Criterion values of the proposed model are -185.64 and -537.76 for the two datasets, which are better than those of the traditional model. Additionally, the proposed prediction method achieves average Cumulative Relative Accuracy values of 0.93 and 0.86, and average Total Mean Square Error values of 25.74 and 28.34 for the two datasets, both of which outperform the prediction methods based on the particle filter and Bayesian principle.

Key words: remaining useful life prediction; Wiener process model; operating conditions; ensemble Kalman filter; particle filter

(责任编辑: 李娟)