

DOI: 10.19650/j.cnki.cjsi.J2108413

失效物理与数据驱动融合的燃油泵在线寿命预测*

景 博¹, 崔展博¹, 孙宏达^{1,2}, 焦晓璇¹, 章 余¹

(1. 空军工程大学航空工程学院 西安 710038; 2. 中国人民解放军 93032 部队 延吉 136200)

摘 要:针对机载燃油泵性能退化过程呈现的多阶段、非线性特点以及对寿命预测实时性的要求,提出了一种基于失效物理与数据驱动融合的燃油泵在线退化建模与寿命预测方法。通过开关卡尔曼滤波器对燃油泵退化阶段进行在线识别,并对快速退化阶段建立失效物理与数据驱动融合的退化模型,然后基于无迹卡尔曼滤波器对建立的退化模型不断进行模型参数更新,并使用更新后的模型对失效寿命进行预测。将所提方法分别与纯数据驱动的方法、不进行退化阶段识别以及不进行参数更新的融合方法进行比较,整个参数更新过程中其均方根误差不超过 0.3,寿命预测百分比误差不超过 2%,均小于对比方法,验证了本文方法的有效性与优越性。

关键词: 机载燃油泵;失效物理;数据驱动;退化建模;寿命预测;参数更新

中图分类号: TP277 TH35 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Online life prediction of the fuel pump based on failure physics and data-driven fusion

Jing Bo¹, Cui Zhanbo¹, Sun Hongda^{1,2}, Jiao Xiaoxuan¹, Zhang Yu¹

(1. Aviation Engineering School, Air Force Engineering University, Xi'an 710038, China; 2. Unit 93032 of PLA, Yanji 136200, China)

Abstract: The performance degradation process of the airborne fuel pump has of multi-stage and nonlinear characteristics, which requires real-time life prediction. To address these issues, an online degradation model and a life prediction method based on failure physics and data driven are proposed. The fuel pump degradation stage is identified online by the switching Kalman filter, the degradation model of rapid degradation stage is formulated based on failure physics and data-driven method, the model parameters are continuously updated based on the unscented Kalman filter, and the failure life is predicted by using the updated model. The proposed method is compared with the data-driven method, the fusion method without degradation stage identification or parameters update. The root mean square value is less than 0.3 during the whole parameter update process, and the percentage error of lifetime prediction is less than 2%, which are smaller than the values of the compared method. The effectiveness and superiority of the proposed method are verified.

Keywords: airborne fuel pump; physics of failure; data driven; degradation model; life prediction; parameter update

0 引 言

机载燃油泵是飞机燃油系统的重要组成部分,然而,由于其工作环境复杂多变,工作过程中会受到振动、过载、高温转换、油液侵蚀等环境应力的影响,因此经常会出现磨损、腐蚀、裂纹等故障,造成燃油泵输送燃油能力下降,影响着飞行安全及作战任务的顺利完成。因此,有必要对其失效寿命进行预测。

近年来,寿命预测技术的研究朝着多样性、体系性和普适性方向快速发展,目前寿命预测方法主要包括基于失效物理的方法(physics of failure, POF)、数据驱动的方法(data driven, DD)以及二者融合的方法^[1]。基于失效物理的方法通过建立描述设备退化机理的失效物理方程,结合设备相关环境参数与特定设备的经验知识和缺陷增长方程实现设备的剩余寿命预测^[2]。Li 等^[3]使用嵌入式模型、齿轮动力学模型和断裂力学模型对齿轮疲劳裂纹进行了预测研究;吕卫民等^[4]基于失效物理的寿

命预测流程并结合有限元仿真技术对电路板寿命进行了预测。然而,基于失效物理的方法虽然能够准确描述设备的退化过程,对寿命预测精度比较高,但是其模型参数很难确定,而且不能充分利用设备的运维数据,无法反应设备的实际退化情况,因此基于数据驱动的方法应运而生。基于数据驱动的分析方法通过对机电设备历史运维数据的分析处理,建立数据的特征规律数学方程,通过模型外推实现寿命预测^[5]。焦晓璇等^[6]通过监测燃油泵出口压力信号并采用自适应差分变异的狼群支持向量机对其寿命进行了预测;Sun等^[7]通过建立退化数据和寿命数据相结合的漂移维纳过程退化模型对机载燃油泵的寿命进行预测;彭宇等^[8]介绍了数据驱动故障预测和健康管理(prognostics and health management, PHM)方法的研究现状,并以锂离子电池循环寿命预测为例分析了数据驱动PHM的实现过程。然而,基于数据驱动的方法对退化数据所包含的退化信息依赖性比较高,寿命预测的准确性取决于获取的退化数据的准确性及真实性,不能反应设备的失效物理过程。而融合的寿命预测方法将基于模型的方法和数据驱动的方法相结合,可以充分发挥各自的优势,克服各自的局限性,实现对设备剩余寿命更精确的预测。然而该方法过程相对比较复杂,目前有关其研究相对较少^[9],Cheng等^[10]提出了一种数据驱动和失效物理相融合的寿命预测方法用于预测电子产品的剩余寿命,取得了较好的预测结果;Liu^[11]利用物理模型和状态监测数据建立了一种综合的轴承预测方法,并使用两组数据验证了所提方法的有效性;Chen等^[12]建立了一种基于模型和数据驱动相结合的剩余寿命预测方法,采用粒子滤波方法对模型参数进行更新,并使用实验数据对所提方法进行了验证。

基于以上原因,本文采用基于失效物理与数据驱动融合的退化建模与寿命预测方法,首先针对退化过程多阶段问题,采用开关卡尔曼滤波器(switching Kalman filter, SKF)对退化阶段进行识别,当识别到进入快速退化阶段时,采用失效物理与数据驱动融合的方法对该退化阶段进行退化建模,并采用无迹卡尔曼滤波器(unscented Kalman filter, UKF)对模型参数进行在线更新,最后使用更新后的模型对失效寿命进行预测。使用燃油泵退化试验数据对上述建模与寿命预测方法进行了实例验证,并与其它方法进行了比较,结果表明所提方法能够实现对寿命的精确预测,其拟合优度和预测精度均高于对比方法。

1 性能退化阶段识别与退化模型的建立

1.1 基于 SKF 的性能退化阶段识别

SKF 是由 Murphy 提出的,并广泛应用于生物医学、控制系统和寿命预测等领域^[13]。基于 SKF 的性能退化

阶段识别的基本思想是,针对系统不同退化状态构建多个标准卡尔曼滤波器,分别计算每个时刻的退化数据对应的各个标准卡尔曼滤波器的概率,从而获得各退化阶段的置信度水平,根据概率大小确定其所处的退化阶段^[14]。采用 SKF 进行退化阶段识别的流程如图 1 所示,具体步骤如下:

- 1) 建立多个退化模型:根据积累的机电设备退化过程经验知识,判断其可能经历的退化阶段,然后建立各阶段对应的退化模型;
- 2) 数据滤波处理:将实时获得的退化数据输入到各个滤波器模型,计算各滤波器对应的后验状态估计 X_k^i 、后验估计协方差 P_k^i 、测量残差 V_k^i 和残差协方差 C_k^i ;
- 3) 退化阶段识别:计算各滤波器模型的概率 S_k^i ,随着退化阶段的变化,各模型概率也会相应的发生变化,根据各模型概率的大小即可判断当前所处的退化阶段。




图1 基于 SKF 的退化阶段识别
Fig. 1 Degradation stage identification based on SKF

1.2 基于 Archard 磨损模型的燃油泵退化模型建立

基于失效物理的寿命预测方法通过对设备的结构、材料及失效机理的分析,明确设备因各种应力作用产生腐蚀、磨损、疲劳、蠕变、断裂而导致设备失效的退化过程,最终外推到对失效寿命的预测。但是其模型参数很难确定,而且不能充分利用设备的运维数据,无法反应设备的实际退化情况。因此,本文采用基于失效物理与数据驱动融合的退化建模与寿命预测方法。

根据燃油泵的失效机理,确定其电机轴承磨损为主要失效模式,因此基于 Archard 磨损模型^[15]建立燃油泵出口压力退化模型。

轴承磨损中主要存在黏着磨损和磨粒磨损两种磨损方式,基于 Archard 模型的黏着磨损公式为:

$$V = k_s \frac{F_N}{3\delta_s} x$$

(1)

基于 Archard 模型的磨粒磨损公式为:

$$V = k_s \frac{F_N}{H} x \quad (2)$$

其中, V 表示磨损体积, k_s 表示磨损系数, x 表示相对滑动距离, δ_s 表示接触对中较软材料的受压屈服极限, H 表示接触对中较软材料的硬度。由黏着磨损式(1)和磨粒磨损式(2)可以看出, 磨损体积 V 与接触面的法向载荷 F_N 、相对滑动距离 x 以及接触面的特性有关。磨损系数 k_s 与接触面的接触状况有关, 根据磨损类型可以将其分为黏着磨损系数和磨粒磨损系数。

由于在轴承磨损过程中两种磨损方式同时存在, 而它们的 Archard 公式又具有相似的表达形式, 因此本文将二者进行融合, 使用强度 δ_s 作为衡量接触对中较软材料的磨损特性, 将轴承磨损公式统一定义如下:

$$V = k_s \frac{F_N}{\delta_s} x \quad (3)$$

由于轴承位于电机内部, 实际工作过程中无法直接采集其接触面的接触压力, 因此可通过有限元仿真模拟的方法获得其大小, 强度 δ_s 的值与材料的特性有关。

通过有限元仿真模拟的方法可以获得接触压力与磨损体积之间的关系如图 2 所示。由图 2 可以看出, 轴承接触面的接触压力不会维持恒定, 而是随磨损量的变化而变化, 因此在整个寿命周期内不能直接使用式(3)进行轴承磨损体积的计算。而在一个微小的相对滑动距离 dx 内, 其接触压力 F_N 可以认为是恒定的, 因此式(3)可表示成式(4), 其中 dV 为 dx 滑动距离内的磨损体积。

$$dV = k_s \frac{F_N}{\delta_s} dx \quad (4)$$




图 2 接触压力与磨损体积的关系

Fig. 2 Relationship between contact pressure and wear volume

在燃油泵工作过程中, 其电机内部的石墨轴承高速旋转, 假设转速为 n , 轴承的半径为 R , 因此, 在 dt 时间内石墨轴承与轴相对滑动距离 dx 可表示为:

$$dx = 2\pi R \cdot n \cdot dt \quad (5)$$

于是式(4)可进一步表示为:

$$dV = \frac{2\pi R}{\delta_s} k_s (V) F_N (V) n(t) \cdot dt \quad (6)$$

对式(6)进一步变形, 可得单位时间内的磨损体积变化, 即轴承的磨损率为:

$$\omega = \frac{dV}{dt} = \frac{2\pi R}{\delta_s} k_s (V) F_N (V) n(t) \quad (7)$$

由式(7)可知, 磨损率会随着接触状态的变化而变化, 由于在 dt 时间内, 磨损体积 dV 非常小, 因此可认为磨损系数 k_s 和接触压力 F_N 保持不变, 而磨损量又为时间的函数, 因此 k_s 和 F_N 也都是时间的函数, 于是式(7)可表示为:

$$\omega(t) = \frac{2\pi R}{\delta_s} k_s (V(t)) F_N (V(t)) n(t) \quad (8)$$

因此, 在时间 t_0 至 t_r 内, 轴承磨损量可表示为:

$$V = \int_{t_0}^{t_r} \omega(t) \cdot dt = \frac{2\pi R}{\delta_s} \cdot \int_{t_0}^{t_r} k_s (V(t)) F_N (V(t)) n(t) \cdot dt \quad (9)$$

因为该型燃油泵的电机为恒速电机, 因此其转速 $n(t)$ 一定, 也即 $n(t)$ 与 t 无关, 于是式(9)可进一步表示为:

$$V = \frac{2\pi R n}{\delta_s} \cdot \int_{t_0}^{t_r} k_s (V(t)) F_N (V(t)) \cdot dt \quad (10)$$

磨损系数 k_s 表示磨擦副的本质特性, 它与材料的性质以及磨擦副的接触特性有关, 会随着磨损体积 V 的变化而变化。有研究表明, 在同一个磨损阶段内磨损系数 k_s 可认为保持恒定^[16], 因此式(10)可进一步表示为:

$$V = \frac{2\pi R n}{\delta_s} k_s \cdot \int_{t_0}^{t_r} F_N (V(t)) \cdot dt \quad (11)$$

由式(11)可知, 只需知道轴承转动过程中各个时刻磨擦副的接触应力, 便可以计算出轴承的磨损状态, 然后根据燃油泵出口压力失效阈值所对应的轴承磨损状态便可以计算出燃油泵的寿命。

接触压力 F_N 与相对滑动距离 x 之间近似满足双指数模型, 而 $x = n \cdot t$, 即接触压力 F_N 与时间 t 也满足双指数模型, 假设其关系式为 $F_N(t) = ae^{bt} + ce^{dt}$, 则式(11)可以写成:

$$V = \frac{2\pi R n}{\delta_s} k_s \cdot \int (ae^{bt} + ce^{dt}) \cdot dt = \frac{2\pi R n}{\delta_s} k_s \cdot \left(\frac{a}{b} e^{bt} + \frac{c}{d} e^{dt} + m \right) = p_1 \cdot e^{p_2 t} + p_3 \cdot e^{p_4 t} + p_5 \quad (12)$$

燃油泵性能退化规律符合轴承磨损退化规律, 因此根据式(12)建立出口压力的退化模型为:

$$y = q_1 \cdot e^{q_2 t} + q_3 \cdot e^{q_4 t} + q_5 \quad (13)$$

其中, q_1, q_2, q_3, q_4, q_5 为待拟合参数, y 为燃油泵出口压力。

2 在线寿命预测方法

2.1 基于 UKF 的模型参数更新方法

卡尔曼滤波器 (Kalman filter, KF) 只能处理线性系统的问题^[17], 然而机电设备的退化过程大多是非线性的, 因此标准的 KF 方法不能再适用。UKF 是在 KF 基础上建立的, 使用无迹变换 (unscented transform, UT) 将非线性系统的原状态用符合高斯分布的一些采样点代替, 避免了系统线性化过程引起的线性化误差, 可以用于非线性系统的状态估计与参数更新^[18]。

为了使建立的退化模型能够更好的描述机电设备的退化过程, 需要使用最新获取的退化数据对模型参数进行不断更新, 首先需要建立如式 (14) 和 (15) 的模型参数的非线性状态空间模型^[19]:

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k, u_k) + w_k \quad (14)$$

$$\mathbf{y}_k = g(\mathbf{x}_k, u_k) + v_k \quad (15)$$

其中, f, g 表示非线性函数, $\mathbf{x}_k$ 为系统状态向量, $\mathbf{y}_k$ 为系统输出向量, u_k 为系统输入, w_k 为协方差为 Q_k 的系统噪声, v_k 为协方差为 R_k 的测量噪声。

接下来对状态变量采用 UT 变换, 即根据一定的采样规则对状态先验分布进行采样, 采样时应满足采样点 (也即 sigma 点) 的均值和协方差状态分布与被采样对象的均值和协方差相同, 即 $mean(\tilde{\mathbf{x}}_i) = \bar{\mathbf{x}}, cov(\tilde{\mathbf{x}}_i) = P_{xx}$, 然后通过对这些 sigma 点进行非线性变换得到对应的非线性函数点集 $\tilde{\mathbf{y}}_i = f(\tilde{\mathbf{x}}_i)$, 这些变换后的点集的均值和协方差与系统实际测量值的均值和协方差近似相等, 即 $mean(\tilde{\mathbf{y}}_i) = \bar{\mathbf{y}}, cov(\tilde{\mathbf{y}}_i) = P_{yy}$ 。

通常采用 $2n+1$ 个 sigma 点进行对称采样, 其值及对应的权值如下所示。

$$\tilde{\mathbf{x}}_i = \begin{cases} \bar{\mathbf{x}}, & i = 0 \\ \bar{\mathbf{x}} + \sqrt{(n+\lambda)P_{xx}}^{(i)}, & i = 1, 2, \dots, n \\ \bar{\mathbf{x}} - \sqrt{(n+\lambda)P_{xx}}^{(i)}, & i = n+1, \dots, 2n \end{cases} \quad (16)$$

$$\omega_i^m = \begin{cases} \lambda/(n+\lambda), & i = 0 \\ 1/2(n+\lambda), & i = 1, 2, \dots, 2n \end{cases} \quad (17)$$

$$\omega_i^c = \begin{cases} \lambda/(n+\lambda) + (1+\alpha^2+\beta), & i = 0 \\ 1/2(n+\lambda), & i = 1, 2, \dots, 2n \end{cases} \quad (18)$$

其中, $\bar{\mathbf{x}}$ 为均值, P_{xx} 为协方差, $\lambda = \alpha^2(n+\kappa)$ 为比例系数, κ 要使 $(n+\lambda)P_{xx}$ 为半正定矩阵, $(\sqrt{(n+\lambda)P_{xx}})^i$ 为加权协方差矩阵的平方根的第 i 列, α 为比例系数, 其大小表示 sigma 点与均值 $\bar{\mathbf{x}}$ 的距离, β 为包含先验分布高阶矩信息的量。

基于 UKF 的模型参数更新步骤如表 1 所示, 主要包括初始化、预测步和更新步。首先经过初始化步骤, 获取

初始 sigma 点; 然后通过式 (14) 和 (15) 对初始 sigma 点进行处理获得下一时刻系统状态预测值 $\hat{\mathbf{x}}(k|k-1)$ 和系统输出预测值 $\hat{\mathbf{y}}(k|k-1)$, 并根据预测值计算协方差矩阵 $P(k|k-1)$ 的值; 最后根据预测值分别计算协方差 P_{yy}, P_{xy} 和卡尔曼增益 K_k , 并通过实际获取的退化数据 y_k 对退化模型参数 $\hat{\mathbf{x}}_k$ 进行迭代更新, 同时获取状态后验方差矩阵 $P(k)$, 用于下一时刻退化模型参数的更新。

2.2 融合的在线寿命预测方法

基于 POF 与 DD 融合的在线寿命预测方法的具体步骤如下:

- 1) 退化阶段识别: 采用 SKF 对退化过程进行在线阶段识别, 当识别到进入快速退化阶段时, 转步骤 2);
- 2) 建立初始退化模型: 采用已获取的快速退化阶段的数据对失效物理模型进行参数拟合, 获取初始退化模型;
- 3) 模型更新: 根据新获取的退化数据采用 UKF 对建立的模型参数不断更新, 获取最新退化模型;
- 4) 失效寿命预测: 对更新后的退化模型进行外推, 结合失效阈值对其失效寿命进行预测。

表 1 基于 UKF 的模型参数更新

Table 1 Model parameters update based on UKF

初始化	1. 计算样本均值和协方差: $\bar{\mathbf{x}}_0 = E(\mathbf{x}_0)$ $P_0 = E((\mathbf{x}_0 - \bar{\mathbf{x}})(\mathbf{x}_0 - \bar{\mathbf{x}})^T)$
	2. 由式 (16) 生成 sigma 点: $\tilde{\mathbf{x}}_i(k-1 k-1)$
预测步	3. 计算系统状态下一时刻预测值: $\tilde{\mathbf{x}}_i(k k-1) = f(\tilde{\mathbf{x}}_i(k-1 k-1), u(k-1))$ $\hat{\mathbf{x}}(k k-1) = \sum_{i=0}^{2n} W_i^m \tilde{\mathbf{x}}_i(k k-1)$
	4. 计算系统输出下一时刻预测值: $\tilde{\mathbf{y}}_i(k k-1) = h(\tilde{\mathbf{x}}_i(k k-1), u(k))$ $\hat{\mathbf{y}}(k k-1) = \sum_{i=0}^{2n} W_i^m \tilde{\mathbf{y}}_i(k k-1)$
	5. 计算方差矩阵下一时刻预测值: $P(k k-1) = \sum_{i=0}^{2n} W_i^c (\tilde{\mathbf{x}}_i(k k-1) - \hat{\mathbf{x}}(k k-1))(\tilde{\mathbf{x}}_i(k k-1) - \hat{\mathbf{x}}(k k-1))^T + Q_k$
	6. 计算系统协方差: $P_{yy} = \sum_{i=0}^{2n} W_i^c (\tilde{\mathbf{y}}_i(k k-1) - \hat{\mathbf{y}}(k k-1))(\tilde{\mathbf{y}}_i(k k-1) - \hat{\mathbf{y}}(k k-1))^T + R_k$ $P_{xy} = \sum_{i=0}^{2n} W_i^c (\tilde{\mathbf{x}}_i(k k-1) - \hat{\mathbf{x}}(k k-1))(\tilde{\mathbf{y}}_i(k k-1) - \hat{\mathbf{y}}(k k-1))^T + R_k$
更新步	7. 计算卡尔曼增益: $K_k = P_{xy} P_{yy}^{-1}$ 8. 计算状态更新后的值: $\hat{\mathbf{x}}(k) = \hat{\mathbf{x}}(k k-1) + K_k(y(k) - \hat{\mathbf{y}}(k k-1))$ 9. 计算状态后验方差矩阵: $P(k) = P(k k-1) - K_k P_{yy} K_k^T$

3 燃油泵退化数据实例验证

3.1 退化数据获取

选用机载燃油泵性能退化试验^[20]获取的燃油泵出口压力退化数据进行退化建模与寿命预测研究,该试验数据为机载燃油泵在电应力和机械振动耦合作用下的出口压力数据。经过初步分析,选用第 9 组试验数据为对象进行研究,这是因为本组试验获取了燃油泵的实际失效寿命,便于对所提退化建模与寿命预测方法的有效性进行验证。

燃油泵出口压力退化曲线如图 3 所示,可以看出,其退化过程存在着明显的两个阶段,且由于燃油泵个体之间存在差异,退化曲线也略有不同。其中试验件 43 的退化曲线明显与其他 4 件不同,可能是由于该台燃油泵退化失效的主要模式发生了变化,因此舍弃该台燃油泵的试验数据。在剩余的 4 组退化数据中,选用试验件 42 的出口压力退化数据进行退化建模与寿命预测研究。试验共采集出口压力 450 次,当采集到第 432 次时,燃油泵出口压力已小于其失效阈值,因此判定其失效寿命为 432 h。




图 3 燃油泵出口压力退化曲线

Fig. 3 Pressure degradation curves of the fuel pump

3.2 退化阶段识别

采用基于 SKF 的性能退化阶段识别方法对燃油泵的退化过程进行在线识别,参考文献[21]针对燃油泵退化数据的不同退化状态分别构建一阶和二阶卡尔曼滤波器用于描述平稳退化过程和快速退化过程,计算每个时刻的退化数据对应的这两个标准卡尔曼滤波器的概率,并绘于同一坐标图中,如图 4(d)所示。通过比较各模型的概率大小判断退化数据所处的退化阶段,同时考虑到因个别异常数据点导致的模型概率变化,造成退化阶段误判的情况,设置只有连续 30 次出现模型概率发生变化时,才判定退化阶段真正发生了变化。由图 4(d)可以看




图 4 基于 SKF 的退化阶段识别

Fig. 4 Degradation stage identification based on SKF

出,虽然在 $t=219$ h 之前模型概率发生了变化,但由于未满足连续发生 30 次的条件,因此均认为退化模式未发生改变,直至 $t=219$ h 时,才判定燃油泵开始进入快速退化阶段。图 4(a) ~ (c) 分别给出了当 $t=50$ 、150 和 250 h

时,基于 SKF 的性能退化阶段识别方法对退化阶段的识别过程,通过对比图 4(a)~(d)可知,SKF 方法对退化阶段的识别效果不受已获取退化数据量的限制,因此可以用于在线退化阶段识别。

为了验证基于 SKF 的方法对燃油泵性能退化阶段识别的有效性,采用多项式逼近的性能退化阶段识别方法^[16]对上述燃油泵出口压力退化数据进行退化阶段识别。对燃油泵退化数据按照式(19)进行多项式拟合,通过式(20)计算其曲率变化曲线。

$$y = f(t) = p_1 t^n + p_2 t^{n-1} + \cdots + p_n t + p_{n+1} \quad (19)$$

$$K_p = \frac{|f''(t)|}{[1 + f'(t)^2]^{3/2}} \quad (20)$$

如图 5 所示,结合曲率变化曲线和多项式拟合曲线,判定其退化轨迹的拐点为 $t = 201$ h,这与 SKF 方法计算得到的 $t = 219$ h 的误差百分比为 3.65%,在可接受的范围内,因此验证了 SKF 方法计算结果的正确性。




图 5 基于多项式逼近的退化阶段识别


Fig. 5 Degradation stage identification based on the polynomial approximation

由于基于多项式逼近的性能退化阶段识别方法需要获取完整的退化过程数据才能进行退化阶段识别,无法像 SKF 方法那样进行在线退化阶段识别,因此,本文选用 SKF 方法进行退化阶段的在线识别。


3.3 模型建立、更新与失效寿命预测

当识别到进入快速退化阶段时,便使用新的退化阶段的燃油泵出口压力退化数据进行退化模型的建立。选取新的退化阶段的前 100 次测量数据(即第 220~319 h 的退化数据)对式(13)的模型参数进行初始化,使用最小二乘法计算得到模型参数的初始值为: $q_1 = -0.453$, $q_2 = 7.4 \times 10^{-3}$, $q_3 = 86.471$, $q_4 = 2.262 \times 10^{-4}$, $q_5 = -26.867$, 然后通过新获取的燃油泵出口压力退化数据,采用 UKF 对模型参数进行不断更新,并使用更新后的退化模型对燃油泵的失效寿命进行预测。图 6 给出了新的数据分别更新 10、50 和 100 个数据点时燃油泵的寿命预测曲线,图 7 给出了寿命预测结果及百分比误差随


数据更新数量变化的曲线。由图 6 和 7 可知,随着新的退化数据的不断获取与模型参数的更新,对燃油泵失效寿命的预测也越来越准确。



(a) 更新10个数据点
(a) 10 data points updating



(b) 更新50个数据点
(b) 50 data points updating



(c) 更新100个数据点
(c) 100 data points updating

图 6 不同数据更新个数条件下燃油泵寿命预测曲线
Fig. 6 Life prediction curves of fuel pump with different numbers of data

3.4 结果分析

为了验证本文提出的基于 SKF-UKF 的 POF 与 DD 融合的退化建模及寿命预测方法的优越性,将本文方法分别与纯数据驱动的方法、不进行退化阶段识别以及不进行参数更新的融合方法进行比较。用于对照验证的方法具体设置如表 2 所示:方法 1 为纯数据驱动的方法,通过对退化数据的分析,选用 4 阶多项式模型进行退化建模,并进行退化阶段识别和模型参数更新,其他设置与本




图 7 寿命预测结果与误差百分比随数据更新数量变化曲线
Fig. 7 Curves of life prediction result and error percentage with the number of data

文方法相同;方法 2 采用 POF 与 DD 融合的方法,但不进行退化阶段识别,只进行模型参数更新,退化数据前 319 小时的所有数据(即第 1~319 h 的数据)用于初始参数的计算;方法 3 同样采用 POF 与 DD 融合的方法,但只进行退化阶段识别,不进行参数更新,其它设置与本文方法相同;方法 4 为本文所提出的基于 SKF-UKF 的 POF 与 DD 融合的退化建模及寿命预测方法。

表 2 不同退化建模方法配置情况

方法序号	建模方法	是否退化阶段识别	是否参数更新
1	数据驱动	是	是
2	融合方法	否	是
3	融合方法	是	否
4	融合方法	是	是

分别采用拟合均方根误差和寿命预测百分比误差对 4 种方法进行比较:

1) 拟合均方根误差

采用均方根误差来衡量 4 种退化建模方法对快速退化阶段退化数据的拟合效果,图 8 给出了拟合均方根误差随参数更新步数的变化过程。由图 8 可知,本文方法建立的退化模型拟合结果的均方根误差基本维持不变;方法 1 拟合结果的均方根误差波动较大,这是因为纯数据驱动的方法对数据依赖性较强,受数据变化影响较大;方法 2 拟合结果的均方根误差初始较小,但随着退化数据的不断获取其值逐渐增大,这是由于方法 2 初始参数包含了缓慢退化阶段的信息,在刚进入快速退化阶段,退化规律与缓慢退化阶段相似度较高,因此刚开始的拟合效果较好,但随着快速退化阶段的加深,此时包含缓慢退化阶段信息的模型对快速退化阶段数据的拟合效果逐渐

变差;方法 3 由于其模型参数得不到有效更新,模型对于后期数据的拟合能力变差,因此其均方根误差随着新数据的不断获取而逐渐增大。




图 8 拟合均方根误差随新获取退化数据的变化曲线
Fig. 8 Curves of fitting RMSE with new data

2) 寿命预测百分比误差

使用百分比误差来衡量 4 种方法对燃油泵寿命预测结果的准确性,图 9 给出了寿命预测百分比误差随参数更新步数的变化过程。总体来看,除方法 3 外,其它 3 种方法的百分比误差均随退化数据更新数量的增加而逐渐减小,这说明随着新的退化数据的不断获取,模型参数也得到了有效更新,所建立的退化模型更加符合退化过程,验证了所提模型参数更新方法的有效性;方法 3 的百分比误差呈一条稳定的直线,这是因为该方法未能对模型参数进行在线更新,所以即使获取了新的退化数据,其退化模型依然保持不变,故该模型的寿命预测值也保持不变;本文方法的预测寿命百分比误差波动最小,且整个参数更新过程其值均处于较低水平;方法 1 在初始阶段其寿命预测的百分比误差较大,但随着参数的更新其值迅速减小,这是因为纯数据驱动的方法不能有效描述机电设备的失效物理过程,在前期退化数据量较小的情况下对退化过程的描述误差较大,而随着新的退化数据的获取,模型对退化过程的描述能力逐渐增强,因此寿命预测的百分比误差迅速减小,甚至最后时刻小于本文提出的方法;方法 2 由于未进行退化阶段的划分,其模型参数初值包含了缓慢退化阶段的大量信息,其退化模型对快速退化阶段的拟合误差较大,因此其寿命预测误差百分比比较其他 3 种方法大。




图 9 百分比误差随更新步数变化曲线
Fig. 9 Curves of percentage error with updated steps

4 结 论

针对机载燃油泵退化过程呈现的多阶段、非线性特点以及对寿命预测实时性的要求,提出了失效物理与数据驱动融合的在线寿命预测方法。通过对退化阶段的划分,针对快速退化阶段建立失效物理与数据驱动融合的退化模型,并对模型参数不断更新,使用更新后的模型预测剩余寿命。通过与纯数据驱动的方法、不进行退化阶段识别以及不进行参数更新的融合方法进行比较,所提方法在整个参数更新过程中,其对快速退化阶段数据拟合均方根误差不超过0.3,寿命预测百分比误差不超过2%,均小于对比方法,验证了本文所提方法的合理性和有效性,能够有效预测燃油泵的失效寿命,为机载燃油泵的可靠性分析提供了可靠支撑。

参考文献

- [1] LIAO L, KOTTIG F. Review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction[J]. IEEE Transactions on Reliability, 2014, 63(1):191-207.
- [2] 金晓航,孙毅,单继宏,等. 风力发电机组故障诊断与预测技术研究综述[J]. 仪器仪表学报, 2017, 38(5):1041-1053.
- JIN X H, SUN Y, SHAN J H, et al. Fault diagnosis and prognosis for wind turbines: An overview[J]. Chinese Journal of Scientific Instrument, 2017, 38(5):1041-1053.
- [3] LI C J, LEE H. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics[J]. Mechanical Systems & Signal Processing, 2005, 19(4):836-846.
- [4] 吕卫民,胡冬,谢劲松. 基于失效物理的电路板寿命预测案例研究[J]. 电子科技大学学报, 2013, 42(4):635-640.
- LYU W M, HU D, XIE J S. Case study on prognostics technique based on pof to predict life of PCB[J]. Journal of University of Electronic Science and Technology of China, 2013, 42(4):635-640.
- [5] 王赞,景博,焦晓璇,等. 基于自适应组合核函数的RVM 剩余寿命预测研究[J]. 电子测量与仪器学报, 2019, 33(6):59-68.
- WANG Y, JING B, JIAO X X, et al. Research on residual life prediction of RVM based on adaptive multi-kernel function[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(6):59-68.
- [6] 焦晓璇,景博,李娟,等. 基于 ADEGWO-SVM 的机载燃油泵寿命预测研究[J]. 仪器仪表学报, 2018, 39(8):43-52.
- JIAO X X, JING B, LI J, et al. Research on remaining useful life prediction of fuel pump based on adaptive differential evaluation grey wolf optimizer-support vector machine[J]. Chinese Journal of Scientific Instrument, 2018, 39(8):43-52.
- [7] SUN M, JING B, JIAO X X, et al. Research on life prediction of airborne fuel pump based on combination of degradation data and life data[C]. 2018 Prognostics and System Health Management Conference (PHM-Chongqing), 2018:664-668.
- [8] 彭宇,刘大同. 数据驱动故障预测和健康管理综述[J]. 仪器仪表学报, 2014, 35(3):481-495.
- PENG Y, LIU D T. Data-driven prognostics and health management: A review of recent advances[J]. Chinese Journal of Scientific Instrument, 2014, 35(3):481-495.
- [9] HU C H, PEI H, SI X S, et al. A prognostic model based on dbn and diffusion process for degrading bearing[J]. IEEE Transactions on Industrial Electronics, 2020, 67(10):8767-8777.
- [10] CHENG S, PECHT M. A fusion prognostics method for remaining useful life prediction of electronic products[C]. Conference of the Society for Machinery Failure Prevention Technology, 2009:285-298.
- [11] LIU T Y. An integrated bearing prognostics method for remaining useful life prediction [D]. Montreal: Concordia University, 2013.
- [12] CHEN C, PECHT M. Prognostics of lithium-ion batteries using model-based and data-driven methods[C]. 2012 Prognostics and System Health Management Conference (PHM-Beijing), 2012:1-6.
- [13] 崔玲丽,王鑫,王华庆,等. 基于改进开关卡尔曼滤波的轴承故障特征提取方法[J]. 机械工程学报, 2019, 55(7):44-51.
- CUI L L, WANG X, WANG H Q, et al. Feature extraction of bearing fault based on improved switching kalman filter[J]. Journal of Mechanical Engineering, 2019, 55(7):44-51.
- [14] LIM C K R, MBA D. Switching Kalman filter for failure prognostic [J]. Mechanical Systems and Signal Processing, 2015, 52:426-435.
- [15] YU G, XIA W, SONG Z, et al. Wear-life analysis of

- deep groove ball bearings based on Archard wear theory[J]. Journal of Mechanical Science and Technology, 2018,32(7):3329-3336.
- [16] 方鑫. 关节轴承协调接触模型与磨损寿命预测[D]. 长沙:国防科技大学, 2014.
- FANG X. Conformal contact model and wear life prediction for spherical plain bearings[D]. Changsha: University of Defense Technology, 2014.
- [17] 姜浩楠, 蔡远利. 带有噪声递推估计的自适应集合卡尔曼滤波[J]. 控制与决策, 2018,33(9):1567-1574.
- JIANG H N, CAI Y L. Adaptive ensemble Kalman filter with recursive noise estimation [J]. Control and Decision, 2018,33(9):1567-1574.
- [18] 阙子俊, 金晓航, 孙毅. 基于 UKF 的轴承剩余寿命预测方法研究[J]. 仪器仪表学报, 2016, 37(9): 2036-2043.
- QUE Z J, JIN X H, SUN Y. Remaining useful life prediction for bearings with the unscented Kalman filter-based approach [J]. Chinese Journal of Scientific Instrument, 2016,37(9):2036-2043.
- [19] 黄玉龙, 张勇刚, 李宁, 等. 一种带有色量测噪声的非线性系统辨识方法[J]. 自动化学报, 2015, 41(11):1877-1892.
- HUANG Y L, ZHANG Y G, LI N, et al. An identification method for nonlinear systems with colored measurement noise[J]. Acta Automatica Sinica, 2015, 41(11):1877-1892.
- [20] 孙宏达, 景博, 焦晓璇, 等. 机载燃油泵复杂应力退化试验设计与应力影响分析[J]. 仪器仪表学报, 2021,42(5):208-218.
- SUN H D, JING B, JIAO X X, et al. Complex stress degradation test design and stress influence analysis of airborne fuel pump [J]. Chinese Journal of Scientific Instrument, 2021,42(5):208-218.

- [21] WANG S L, JING B, JIAO X X, et al. Degradation pattern identification and remaining useful life prediction for mechanical equipment using SKF-EN [J]. IEEE Access, 2020,8:147662-147672.

作者简介



景博,1996 年于空军工程大学获得硕士学位,2002 年于西北工业大学获得博士学位,现为空军工程大学教授,主要研究方向为故障预测与健康管理和测试性设计、传感器网络与信息融合。

E-mail:jingbo_sensor@163.com

Jing Bo received her M. Sc. degree from Air Force Engineering University in 1996 and received her Ph.D. degree from Northwestern Polytechnical University in 2002. She is currently a professor at Air Force Engineering University. Her main research interests include prognostics and health management, design for testability, sensor network and information fusion.



孙宏达(通信作者),2013 年于安徽大学获得学士学位,2021 年于空军工程大学获得硕士学位,现为中国人民解放军 93032 部队助理工程师,主要研究方向为智能检测与健康管理和健康管理。

E-mail:honda_sun@163.com

Sun Hongda (Corresponding author) received his B. Sc. degree in 2013 from Anhui University and M. Sc. from Air Force Engineering University in 2021, respectively. Now he is an assistant engineer in Unit 93032 of PLA. His main research interests include intelligent detection and health management.