

DOI: 10.19650/j.cnki.cjsi.J1905134

基于函数主元分析的多阶段退化过程建模与预测*

张彬¹, 章立军², 罗久飞¹, 张毅¹, Wang Pingfeng³

(1. 重庆邮电大学先进制造工程学院 重庆 400065; 2. 北京科技大学 国家材料服役安全科学中心 北京 100083;
3. 伊利诺伊大学厄巴纳-香槟分校工程学院 厄巴纳 IL 61801)

摘要:退化过程建模与预测作为设备健康管理的基础,是降低运行风险和维护成本的有效途径。为解决实际中退化过程所表现出的随机性、非线性和多阶段复杂性,提出了一种基于函数主元分析的多阶段退化过程自适应建模与预测方法。通过将退化测量值视为连续函数的离散采样值,从而将退化建模问题转换为函数型数据分析问题。在此基础上,利用函数主元分析方法对退化数据进行降维,提取设备退化的共性信息以及个体差异性信息。结合贝叶斯推理,利用在线监测数据更新退化模型参数,实现健康状态的在线实时预测。最后,将所提的方法用于散热风扇的加速寿命试验数据,验证了本方法的有效性。结果表明,所提方法可以地很好建模多阶段的复杂随机退化过程,具有潜在的工程应用价值。

关键词: 多阶段退化;建模与预测;函数主元分析;散热风扇

中图分类号: TH17 文献标识码: A 国家标准学科分类代码: 510.4030

Multi-phase degradation process modeling and prediction based on functional principal component analysis

Zhang Bin¹, Zhang Lijun², Luo Jiufei¹, Zhang Yi¹, Wang Pingfeng³

(1. School of Advanced Manufacturing Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;
2. National Center for Materials Service Safety, University of Science and Technology Beijing, Beijing 100083, China;
3. College of Engineering, University of Illinois at Urbana-Champaign, Urbana IL 61801, USA)

Abstract: As the foundation of equipment health management, the degradation process modeling and prediction is an effective way to reduce running risk and maintenance cost. In order to solve the randomness, nonlinearity and multi-phase complexity of the degradation process in practice, an adaptive modeling and prediction method for multi-phase degradation process based on functional principal component analysis is proposed. This method treats the degradation measurement values as discrete sample values of continuous function, and thus converts the degradation modeling problem into functional data analysis problem. On this basis, this method uses the function principal component analysis method to reduce the dimensionality of the degraded data, and extracts the common information and individual difference information of the equipment degradation. With Bayesian reasoning, the on-line monitoring data is used to update the degradation model parameters to realize on-line real-time prediction of equipment health status. Finally, the proposed method is applied to the accelerated life test data of a cooling fan, and the effectiveness of the method is verified. The results show that the proposed method can well model the multi-phase complex random degradation process and thus has potential engineering application value.

Keywords: multi-phase degradation; modeling and prediction; functional principal component analysis; cooling fan

0 引言

随着先进传感、物联网与信息物理系统等的飞速发展,各类监测传感器在工业中广泛应用,由此产生 TB、PB 甚至以上量级的过程数据,进入“工业大数据”时代。如何有效利用这些海量数据智能评估与预测关键设备的健康状态,已经成为近年来机械健康监测研究的前沿和热点^[1-2]。机械设备运行时间的增加会导致使用性能逐渐退化,有效建模和准确预测设备的性能退化过程,可以为设备维护管理提供有价值的决策信息和足够的响应时间,降低设备的失效风险和维修成本。

由于退化过程固有的随机性,统计模型的方法是当前退化过程建模和预测的主流方法。Lu 等^[3]于 1993 年将随机系数模型引入到退化建模,之后出现了许多的扩展和变形。如 Gebraeel 等^[4]和文献^[5]中通过指数形式的随机系数模型,对轴承退化的振动幅值趋势进行拟合和预测。虽然随机系数模型可以建模个体差异性和测量误差,但却不能描述退化过程在时间上的随机性,因此随机过程方法获得越来越多的关注。其中,Wiener 过程由于可以描述非单调的退化、具有很好的数学性质,广泛应用于退化数据的建模与预测^[6]。Li 等^[7]研究了带测量误差的 Wiener 过程退化分析方法;金晓航等^[8]结合 Copula 函数,研究了基于二元 Wiener 过程的退化建模与预测。进一步考虑退化的不可逆性,则可通过 Gamma 过程进行建模分析,特别是磨损、腐蚀与裂纹增长等累积性退化,建立 Gamma 过程的退化模型具有明确的物理意义^[9]。其他如(隐半)马尔科夫模型、比例风险模型及逆高斯过程等也在退化过程的分析中获得了研究和应用^[10]。除随机性外,退化过程还普遍表现出非线性。Huang 等^[11]研究了自适应漂移非线性异质 Wiener 过程的退化与预测。考虑不确定测量和个体差异性,郑建飞等^[12]研究了基于扩散过程的非线性退化模型。近年来,有学者将研究视角转向函数型数据分析。Zhou 等^[13]基于函数数据分析研究了稀疏和片段退化数据的建模与预测;Cheng 等^[14]通过函数主元分析研究了锂离子电池的剩余寿命预测。函数型数据分析方法将退化轨迹建模为函数曲线,从而可很好处理退化过程在时间上的随机性、非线性。

工程实际中,由于运行环境、负载情况等的动态变化,退化过程还呈现出两阶段甚至多阶段的演变特点。鄢伟安等^[15]研究了液力耦合器的两阶段 Wiener 退化过程,并运用 Schwarz 信息准则进行变点估计;Wang 等^[16]研究了有机发光二极管两阶段退化的贝叶斯变点 Wiener 模型;Wang 等^[17]研究了轴承的两阶段退化,通过 3σ 准则进行变点的估计;文献^[18]通过统计模型估计两阶段

退化的变点,基于贝叶斯理论进行实时预测。对于更为复杂的退化,需要建立更多阶段的退化模型^[19]。李娟等^[20]针对机载燃油泵退化呈现出的非线性、多阶段模式,通过逻辑平滑转换自回归(LSTAR)模型进行建模。Wen 等^[21]假定分阶段线性,研究了多阶段退化预测的一般模型。根据退化过程表现出的多阶段特点,综合考虑各个阶段退化信息,可充分利用全寿命周期数据,提高退化建模与预测的精度。但进行多阶段退化建模与预测需要首先确定变点的位置,而变点位置的确定受多种因素的影响,变化较大,是一个难点问题。另外,进行多阶段退化建模时,通常假设各个阶段退化服从一定的参数化模型(线性或可以线性化的模型),而且分别对单个个体的数据进行处理,容易丢失退化过程的共性信息。

鉴于上述考虑,本文针对实际应用中退化过程所表现出的随机性、非线性和多阶段特点,特别是多阶段复杂性,研究基于函数主元分析的退化过程自适应建模方法,并结合贝叶斯推理,利用在线监测数据对模型中的参数进行更新,实现健康状态的在线实时预测。散热风扇的加速寿命试验研究结果表明,本文方法可以很好地建模多阶段的复杂退化过程,取得了良好的预测效果。

1 基于函数主元分析的多阶段退化建模

1.1 函数型数据下的退化过程建模

退化过程研究中,一般假定设备的性能退化可以通过一定的健康指标(health index, HI)来描述,如振动 RMS、裂纹长度、电池容量、以及各种融合指标。通过状态监测,可以获得多个设备在多个离散时刻的 HI 测量值。由此设备 i 的退化可以表示为:

$$y_{ij} = x_i(t_{ij}) + e_{ij}, i = 1, 2, \dots, I; j = 1, 2, \dots, J_i \quad (1)$$

式中: $x_i(t_{ij})$ 和 y_{ij} 为 t_{ij} 时刻的 HI 及其测量值; e_{ij} 为独立同分布的测量误差,且服从正态分布 $N(0, \sigma^2)$ 。

退化过程的建模,重点在于 HI 随时间变化函数关系的研究。但设备退化表现出的随机性、非线性和多阶段特点,使得从传统离散 HI 序列角度建立这种函数关系变得复杂。而如果视描述设备 i 退化的 HI 为连续函数 $x_i(t)$ 在相应离散时刻 t_{ij} 的采样 $x_i(t_{ij})$,则问题转变为对相应函数曲线的分析,从而建立函数型数据下的退化过程模型。

退化过程本质上为渐变的随机过程,单个设备的退化为该随机过程的一个样本函数,而描述这个设备退化的 HI 是上述连续样本函数在各个离散时刻的采样值。具体地,记退化过程为 $X(t)$, $t \in \Gamma$ (Γ 为设备开始使用至退化失效的时间范围),则其均值 $\mu(t) = E(X(t))$ 、协方差函数 $G(s, t) = E(X(s) - \mu(s))(X(t) - \mu(t))$ (E 为期望算子)。则退化过程建模问题描述为:根据 I 个函数

型数据 $x_i(t)$ 的带误差离散采样测量值 y_{ij} , 研究随机过程 $X(t)$, 以获得退化过程信息, 以及 $x_i(t)$ 的表达式, 并对相似设备的退化进行预测。

1.2 基于函数主元分析的多阶段退化模型

就时间维度而言, 函数型数据是一种无限维的数据, 将其展开成基函数的线性组合而降维, 是对该类数据分析的关键。函数主元分析 (functional principal component analysis, FPCA) 由于能够根据数据自身得到基函数, 获得广泛关注与研究^[22]。

协方差函数是多变量协方差矩阵在函数型数据上的推广, 而且可以证明协方差函数满足非负正定的条件。从而对于退化过程 $X(t)$, 其协方差函数可以进行如下的特征分解:

$$\int_{\Gamma} G(s, t) \varphi_k(t) ds = \lambda_k \varphi_k(t), s, t \in \Gamma$$

$$\text{s.t.} \begin{cases} \int_{\Gamma} \varphi_k^2(t) dt = 1 \\ \int_{\Gamma} \varphi_k(t) \varphi_l(t) dt = 0, l \neq k \end{cases} \quad (2)$$

式中: $\lambda_k (\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{\infty})$ 为降序排列的特征值, $\varphi_k(t)$ 为对应的特征函数。

退化过程 $X(t)$ 协方差函数的特征函数 $\varphi_k(t)$ 反映了退化过程随时间的变动模式, 统计学中也将其称为函数主元。如果以前 K 个函数主元为基函数, 则基于 FPCA 可将描述设备 i 退化的连续函数展开为:

$$x_i(t) = \mu(t) + \sum_{k=1}^K \varepsilon_{ik} \varphi_k(t), t \in \Gamma \quad (3)$$

式中: ε_{ik} 为 $x_i(t)$ 对应于 $\varphi_k(t)$ 的函数主元得分, 计算如式(4); ε_{ik} 关于 k 互不相关, 关于 i 有 $E(\varepsilon_{ik}) = 0, E(\varepsilon_{ik}^2) = \lambda_k$ 。

$$\varepsilon_{ik} = \int_{\Gamma} (x_i(t) - \mu(t)) \varphi_k(t) dt, t \in \Gamma \quad (4)$$

通常仅有少数几个特征值具有重要影响, 而大多数特征值接近于 0, 相应的函数主元得分也接近于 0, 从而可以设定阈值 η (一般不小于 85%), 根据累积贡献率选择合适的函数主元数目 K :

$$K = \min \left(\begin{array}{l} \sum_{k=1}^K \lambda_k \\ \sum_{k=1}^{\infty} \lambda_k \end{array} \geq \eta \right) \quad (5)$$

在函数型数据框架下, 基于 FPCA 进行退化过程建模, 通过退化过程均值函数、少数几个函数主元及其得分实现了退化数据的降维。设备退化的共性信息由模型中的均值函数、函数主元集中体现, 其中均值函数刻画了退化过程的演变趋势、函数主元刻画了退化过程随时间的变动模式; 而单个设备退化的特殊性则通过其函数主元得分加以体现。通过将离散时刻的 HI 视为连续函数的采样值, 直接对整个退化过程进行自适应建模, 从而无需

对多阶段退化的变点进行识别、也弱化了服从一定参数化模型的假设, 具有较好的通用性和潜在工程应用价值。

2 退化模型的参数估计与退化预测

2.1 退化模型的参数估计

为获得退化过程的共性信息和单个设备退化的描述, 需要充分利用给定的 I 个设备从开始使用至退化失效的 HI 的带误差测量序列 $y_i = (y_{i1}, y_{i2}, \dots, y_{iji})^T$, 对模型中的参数进行估计。

对于退化过程的均值函数, 直接通过对 I 个设备 HI 的带误差测量序列的局部线性平滑进行估计:

$$\hat{\mu}(t) = \alpha_0(t)$$

$$\min_{\alpha_0, \alpha_1} \sum_i \sum_j \kappa_1 \left(\frac{t_{ij} - t}{h_{\mu}} \right) (y_{ij} - \alpha_0 - \alpha_1(t_{ij} - t))^2 \quad (6)$$

式中: $\kappa_1(\cdot)$ 为一元核函数; h_{μ} 为对应的平滑带宽。

对于退化过程的协方差函数, 同样可以通过局部平滑的方法进行估计。但是注意到协方差函数存在式(7)的关系, 从而在进行二元平滑估计时, 需要去除带测量误差的对角线上的值, 然后再单独对对角线上的值进行估计, 最后整合得到协方差函数估计 $\hat{G}(s, t)$ 。具体的估计过程可参见文献[23]。

$$V_i(t_{ij}, t_{il}) = (y_{ij} - \hat{\mu}(t_{ij}))(y_{il} - \hat{\mu}(t_{il})) \quad (7)$$

$$E(V_i(t_{ij}, t_{il})) = \hat{G}(t_{ij}, t_{il}) + \sigma^2 \delta_{jl}$$

式中: δ_{jl} 为克罗内克符号, 当且仅当 $j=l$ 时, $\delta_{jl}=1$ 。

进行均值函数及协方差函数的平滑估计时, 可以选用高斯、矩形及 Epanechnikov 等为平滑核函数, 而平滑带宽一般通过交叉验证的方法加以确定。

将退化过程协方差函数估计离散化后, 代入式(2)进行特征分解, 即可得到其函数主元和特征值估计 $\hat{\varphi}_k(t)$ 和 $\hat{\lambda}_k$, 最后再通过样条插值等局部方法对离散函数主元进行平滑以获得连续函数主元。

对于测量误差的方差 σ^2 , 在获得退化过程协方差函数估计的基础上, 按式(8)进行估计。

$$\hat{\sigma}^2 = \max \left(\frac{2}{|\Gamma|} \int_{\Gamma} (\hat{V}(t) - \hat{G}(t, t)) dt, 0 \right) \quad (8)$$

式中: $\hat{V}(t)$ 为式(7)中 $E(V_i(t_{ij}, t_{il}))$ 对角线的局部线性平滑估计; $\Gamma_1 = [|\Gamma|/4, 3|\Gamma|/4]$ 为积分范围; $|\Gamma|$ 为 Γ 的区间长度。

由于建模时考虑了测量误差, 不能直接按式(4)计算函数主元得分。为此, 根据文献[23]提出的条件期望主元分析 (PACE) 方法, 估计设备 i 退化 HI 的函数主元得分:

$$\hat{\varepsilon}_{ik} = \hat{\lambda}_k \hat{\varphi}_{ik}^T \sum_i^{-1} (y_i - \hat{\mu}_i), k = 1, 2, \dots, K \quad (9)$$

式中: $\hat{\varphi}_{ik}, \hat{\mu}_i$ 分别为函数主元 $\hat{\varphi}_k(t)$ 、均值函数 $\hat{\mu}(t)$ 在设

备 i 各离散监测时刻 t_{ij} 的采样值组成的列向量;而 $\hat{\Sigma}_{[i,j]} = \hat{G}(t_{ij}, t_{il}) + \hat{\sigma}^2 \delta_{jl}$ 为在 t_{ij}, t_{il} 时刻协方差函数的采样值所组成的矩阵。

代入退化模型各参数的估计结果,得到描述设备 i 退化的 HI 估计为:

$$\hat{x}_i(t_{ij}) = \hat{\mu}(t_{ij}) + \sum_{k=1}^K \hat{\varepsilon}_{ik} \hat{\varphi}_k(t_{ij}) \quad (10)$$

基于本文所提的 FPCA 退化建模方法,可自适应地根据退化数据估计退化过程均值函数而无需事先假定退化趋势的函数形式,而且还能充分地融合各个设备的退化数据进行模型参数估计。

2.2 退化的实时预测

对仍在运行的未失效设备,对其退化进行预测,是实施状态维护与健康管理的键。基于 FPCA 进行退化建模后,描述未失效设备退化的 HI 表示为式(11)。可以看出设备未来退化预测的关键,在于预测相应的各个函数主元得分 $\varepsilon_k(k=1,2,\dots,K)$ 。

$$x(t) = \mu(t) + \sum_{k=1}^K \varepsilon_k \varphi_k(t), t \in \Gamma \quad (11)$$

贝叶斯推理认为推理结果不仅与所观测到的客观样本信息有关,而且也与积累的先验信息有关。进行推理时应该以先验信息为基础,然后再通过样本的观测值进行更新,最后得到推理结果^[24]。对于未失效设备 HI 的函数主元得分 $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_K)^T$,如果以历史失效设备的 HI 对函数主元得分的估计为先验信息,则基于贝叶斯推理,可以构建未失效设备 HI 的函数主元得分 ε 的推理更新模型为:

$$p(\varepsilon | y_{1:H}) \propto p_0(\varepsilon) p(y_{1:H} | \varepsilon) \quad (12)$$

式中: $p_0(\varepsilon)$ 为 ε 的先验分布; $p(y_{1:H} | \varepsilon)$ 为似然函数,其中 $y_{1:H} = (y_1, y_2, \dots, y_H)^T$ 为到目前为止未失效设备退化 HI 的测量值序列; $p(\varepsilon | y_{1:H})$ 为 ε 的后验分布。

通过前面的分析可知, ε_k 为两两互不相关、均值为 0、方差为 λ_k 的随机变量。由于设备的性能退化是在多种内部、外部环境因素的综合作用下逐渐发生的,可以合理假定退化过程为高斯过程,则函数主元得分将服从正态分布。进一步根据设备退化 HI 的测量值计算似然函数,可以得到:

$$p_0(\varepsilon) \sim N(0, \Lambda), \Lambda = \text{diag}(\hat{\lambda}_1, \hat{\lambda}_2, \dots, \hat{\lambda}_K)$$

$$p(y_{1:H} | \varepsilon) = \frac{1}{\sqrt{2\pi\hat{\sigma}^2}} \left(-\frac{e^T e}{2\hat{\sigma}^2} \right), e = y_{1:H} - \mu_{1:H} - \Phi \varepsilon \quad (13)$$

式中: $\text{diag}(\cdot)$ 为对角线阵; $\mu_{1:H}$ 为均值函数估计 $\hat{\mu}(t)$ 在设备各个测量时刻 $t_h(h=1,2,\dots,H)$ 的采样值所组成的列向量; $\Phi_{[h,k]} = \varphi_k(t_h)(k=1,2,\dots,K)$ 为相应时刻各个函数主元的采样值所组成的矩阵。

由于函数主元得分的先验分布与似然函数为共轭分布,则 ε 的后验分布仍为正态分布。通过推导得到:

$$p(\varepsilon | y_{1:H}) \sim N(\mu_H^\varepsilon, \Sigma_H^\varepsilon)$$

$$\Sigma_H^\varepsilon = \left(\frac{\Phi^T \Phi}{\hat{\sigma}^2} + \Lambda^{-1} \right)^{-1}, \mu_H^\varepsilon = \Sigma_H^\varepsilon \frac{\Phi^T}{\hat{\sigma}^2} (y_{1:H} - \mu_{1:H}) \quad (14)$$

将函数主元得分 ε 的后验分布 $p(\varepsilon | y_{1:H})$ 各个参数代入式(11),则基于最新的退化测量值序列 $y_{1:H}$,得到未失效设备 HI 的实时预测:

$$x(t) \sim N(\mu_H^x(t), \sigma_H^{2x}(t)), t \in \Gamma$$

$$\mu_H^x(t) = \hat{\mu}(t) + \varphi(t)^T \mu_H^\varepsilon, \sigma_H^{2x}(t) = \varphi(t)^T \Sigma_H^\varepsilon \varphi(t) \quad (15)$$

式中: $\varphi(t) = (\hat{\varphi}_1(t), \hat{\varphi}_2(t), \dots, \hat{\varphi}_K(t))^T$ 。

建立基于 FPCA 的退化模型后,单个设备退化的 HI 主要通过函数主元得分确定,而且通过这些主元函数得分的随机性可以很好地描述未失效设备退化的不确定性。以贝叶斯推理为理论基础,可以根据最新退化测量值进行参数更新,实现设备退化的实时预测。

3 案例分析

3.1 散热风扇加速寿命试验

散热风扇作为电子设备散热系统的关键部件,它的运行状态是否良好,决定着电子设备的降温冷却效果。因此,本文通过散热风扇的性能退化,对所提的多阶段退化建模、预测方法进行验证分析。

直流散热风扇性能退化试验如图 1 所示。通过 12 V 稳压电源给散热风扇供电,然后通过加速度传感器与热电偶分别采集其振动和温度信号,同时也对散热风扇的 PCB 电压进行测量。其中信号调理器选用 PCB 482,数据采集系统为 NI USB 6009。试验时,散热风扇通过穿过外壳的 4 个螺丝加以固定,同时为加速风扇的性能退化,在其轴承中加入了少量的金属微粒,并在其中的一个叶片上粘上了一个不平衡配重。用于测量振动与温度的加速度传感器与热电偶安装固定在散热风扇底部,PCB 电压则通过与其连接的两根连线获得,具体如图 2 所示。

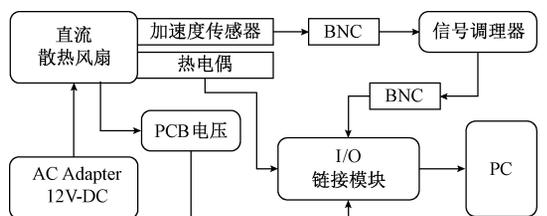


图 1 散热风扇退化试验

Fig.1 Block diagram of the degradation test of a cooling fan

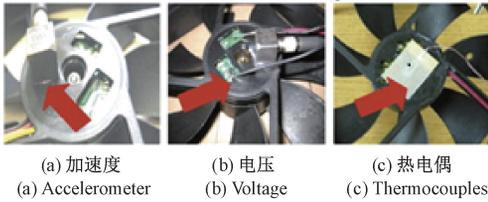


图2 散热风扇传感器安装

Fig.2 The sensor installation of the cooling fan

整个试验过程在相同的状况下,共对32个直流散热风扇进行了加速退化试验,采集了其性能退化直至失效的状态监测数据。通过初期对振动、温度与电压3种监测信号的分析处理,发现温度与电压信号并没有随着散热风扇的性能退化而表现出明显的趋势,而振动信号前5阶共振频率的均方根值则表现出相关的性能退化趋势。此处将直接以该特征作散热风扇性能退化描述的HI,重点研究相关的退化建模。

所有32个散热风扇及其中一个散热风扇的HI如图3所示,振动状态监测的间隔为10min。

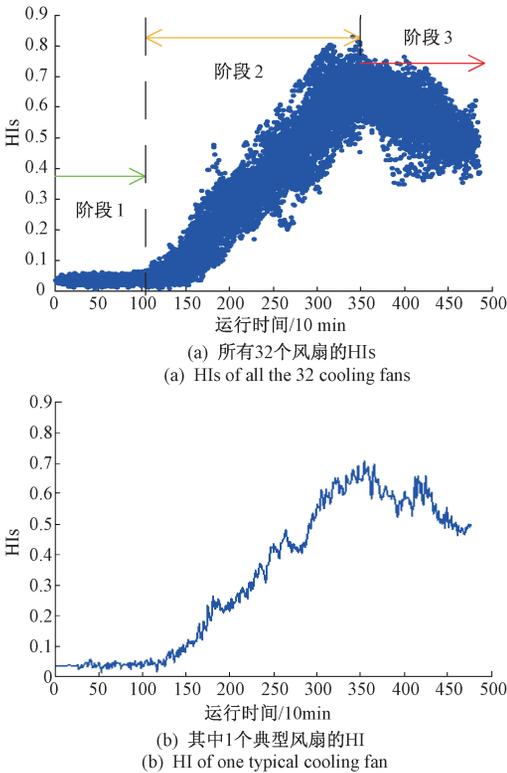


图3 散热风扇的HIs

Fig.3 The HIs of the cooling fan

整体来说,随着散热风扇的退化,HI表现出3阶段特征:1)初期风扇正常运行阶段(约0~1000min),HI维持在较低的水平;2)中期阶段(约1000~3500min),风

扇运行出现异常且持续退化,HI不断上升;3)运行末期(约3500min后),风扇的性能继续劣化,但此时HI却逐渐下降。如果通过传统分段方法建模,则需要确定2个变点位置后再进行3阶段的参数化建模,显得复杂。通过本文所提基于FPCA的自适应方法,可以很好处理这种多阶段复杂性退化的建模问题。

3.2 散热风扇退化建模

以32个散热风扇的HI的带误差测量序列,对FPCA退化模型的参数进行估计。其中退化均值函数、协方差函数估计的平滑核函数分别选用一元、二元高斯核函数,而平滑带宽通过交叉验证加以确定,设定累积贡献率阈值 $\eta = 95\%$,得到退化模型主要参数估计结果如表1所示。可见由于散热风扇退化的多阶段复杂性,需要保留前5个函数主元,才能反映其退化情况。

表1 退化模型的参数估计结果

Table 1 The parameter estimation results of the degradation model

函数主元数目		特征值	测量误差
K	累积贡献率	$\hat{\lambda}_k(k=1,2,\dots,5)$	$\hat{\sigma}^2$
5	0.965 5	(0.794 6, 0.299 6, 0.063 4, 0.028 0, 0.025 8) ^T	0.000 54

风扇退化过程的均值函数估计如图4所示。对比散热风扇退化HI的测量值(图3),可以看出本文方法根据32个风扇的退化数据,自适应地估计出了退化的平均趋势,即正常的平稳运行阶段、出现异常后的持续退化阶段、以及末期的退化失效阶段。

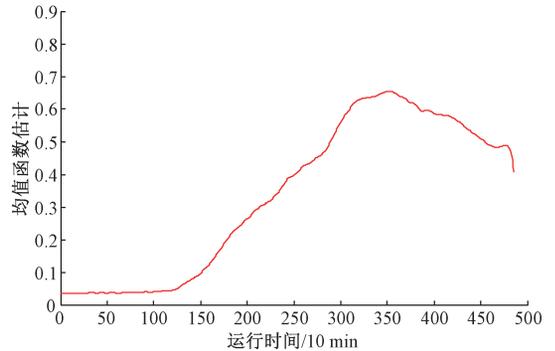


图4 散热风扇HI的均值函数估计

Fig.4 The mean function estimation of the cooling fan HI

风扇退化过程基于FPCA建模后的前5个函数主元(functional principal component, FPC)估计如图5所示。运行初期,各个函数主元取值均接近于0,这与初期风扇运行较平稳、变动小相一致。而在风扇运行出现异常后,5个函数主元则以不同的函数曲线形式体现了退化随运行时间的复杂变动情况。

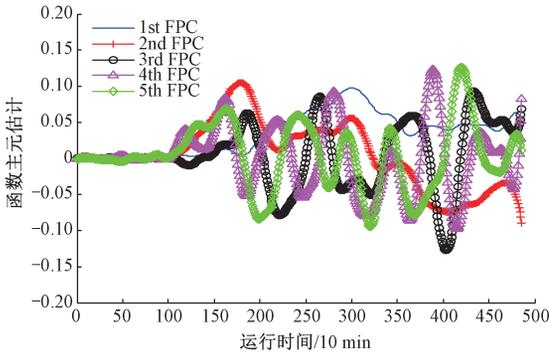


图 5 散热风扇 HI 的函数主元估计

Fig.5 The FPC estimation of the cooling fan HI

单个风扇退化 HI 的特殊性通过其 5 个函数主元得分加以体现,按式(9)计算各个函数主元得分。其中 32 个风扇 HI 的第 5 个函数主元得分估计的直方图如图 6 所示,拟合后,满足 $N(-0.0002, 0.0250)$ 的正态分布,与理论的 $N(0, 0.0258)$ 十分接近;其他 4 个函数主元得分也可得到类似的结果。退化建模中的高斯过程假设是合理的。

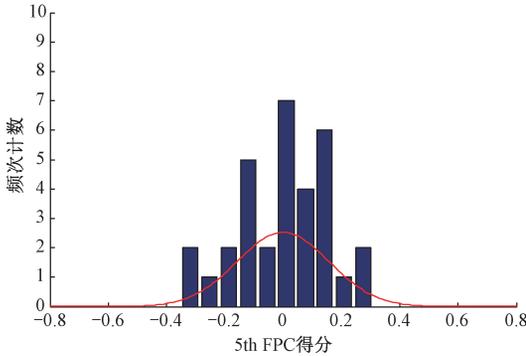


图 6 散热风扇 HI 的第 5 个函数主元得分的直方图

Fig.6 The histogram for the 5th FPC score of the cooling fan HI

为与分段建模方法相比较,需要识别出风扇 3 阶段退化的 2 个变点。对于正常运行阶段到出现异常后的持续退化阶段,以 HI 首次超出正常运行 3σ 范围监测点的前一时刻为变点位置;对于持续退化阶段到末期失效阶段,以最大 HI 所对应的时刻为第 2 个变点位置。由于风扇正常运行阶段,HI 基本在恒定值上下波动、没有趋势,进行比较时将其略去,仅对出现异常后的两阶段退化建模进行比较。退化阶段 2 较简单,线性函数(Poly1)已可以获得很好的建模效果。而对于较复杂的退化阶段 3,同时考虑了线性(Poly1)、3 次多项式(Poly3)和双指数函数(Exp) 3 种参数化方法进行建模。在前述分析基础上,进一步参考文献[3]、[15]等,分别通过线性 Wiener 过程(LWP)对退化阶段 2、及基于 Poly3 的随机系数回归模

型(RCR)对退化阶段 3 进行建模。

为比较建模效果,以式(16)确定系数(R-square)、误差平方和(SSE)及均方根误差(RMSE)为评价指标,对 32 个风扇的统计分析结果如表 2 所示。

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2, RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$R\text{-square} = 1 - \frac{SSE}{SST}, SST = \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (16)$$

式中: y_i 为退化 HI 的测量值; \hat{y}_i 为相应的估计或拟合值; n 为建模点数; \bar{y}_i 为 n 个 HI 测量值的平均值。

表 2 退化建模结果比较

Table 2 Comparison of degradation modeling results

退化阶段	方法	R-square		SSE		RMSE	
		均值	方差	均值	方差	均值	方差
2	FPCA	0.979 8	0.011 1	0.167 1	0.070 9	0.026 3	0.004 9
	Poly1	0.951 6	0.034 2	0.417 8	0.283 3	0.040 5	0.011 0
	LWP	0.918 8	0.048 3	0.742 6	0.521 3	0.053 3	0.017 9
3	FPCA	0.808 2	0.077 8	0.078 6	0.037 5	0.026 4	0.005 4
	Poly1	0.680 9	0.159 8	0.132 3	0.078 0	0.034 2	0.009 2
	Poly3	0.777 7	0.108 5	0.090 2	0.040 8	0.028 5	0.006 1
	Exp	0.757 8	0.115 1	0.099 2	0.047 6	0.029 7	0.006 2
	RCR	0.600 3	0.208 9	0.173 3	0.130 4	0.037 9	0.011 4

可以看出,对于风扇退化阶段 2 和阶段 3,基于 FPCA 建模的 SSE、RMSE 的均值和方差都最小,且 R-square 更接近于 1,说明本文方法具有更好的建模性能。对于分段建模,识别出了分段变点之后,通过 poly1 和 LWP 2 种方法建模较简单的风扇退化阶段 2,都可取得很好的效果;对于较复杂的退化阶段 3,基于 Poly3 单独对每个风扇的退化进行参数化建模取得相对较好的效果,而以 Poly3 函数中的一次项系数为随机项的 RCR 对风扇退化阶段 3 的整体建模效果较差。

图 3(b)中典型风扇退化 HI 的建模结果如图 7 所示。Poly1、LWP 与 RCR 等参数化建模方法可以描述退化的长期趋势,但对退化的局部、短期变化描述能力有限。基于本文方法则可以同时建模退化的短期、长期趋势。

3.3 散热风扇退化预测

为进一步验证分析基于 FPCA 建模与贝叶斯推理的退化实时预测,从所有的 32 个散热风扇中取出 4 个代表性的风扇作为需要进行退化预测的未失效设备,其余风扇为失效设备,开展退化建模与实时预测。

对于本文方法,以失效风扇 HI 估计的参数结果为先验信息,通过截止到预测时刻为止的未失效风扇测量数据对参数进行更新,并进行退化预测。为与参数化方法

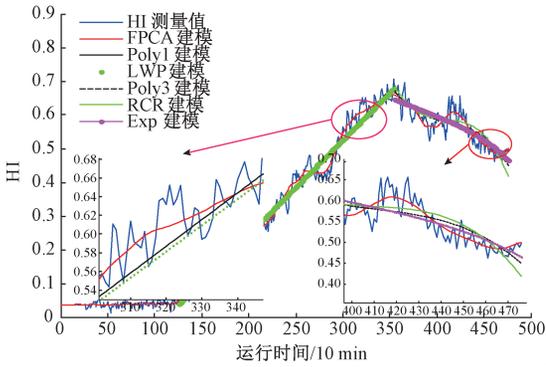


图7 图3(b)散热风扇 HI 的退化建模结果比较
Fig.7 Comparison of the degradation modeling results for the cooling fan HI in Fig. 3 (b)

进行比较,以截止到预测时刻为止的未失效风扇测量数据进行分段退化预测。其中退化阶段2,以 Poly1、LWP 为模型;对于退化阶段3,以效果最优的 Poly3 以及为 RCR 为模型。具体是对风扇运行到其寿命的 50%、60%、70%、80%、85%、90%、95% 等 7 个百分比 $p_i (i=1,2,\dots,7)$ 时间点进行退化预测,前 3 个预测时间点位于退化阶段 2、而后 4 个预测时间点位于退化阶段 3。

对图 3 (b) 中典型风扇,在百分比 p_3 时间点基于 Poly1 和 LWP 对退化阶段 2、在百分比 p_7 时间点基于 Poly3 和 RCR 对退化阶段 3、及在百分比 p_3 时间点基于 FPCA 的退化的预测结果如图 8 所示。此种情况下,参数化模型 Poly1 和 LWP 已有足够的测量历史数据,对退化阶段 2 的长期趋势预测获得了较好效果;对于退化阶段 3,虽然有充裕的监测数据,但预测结果却不理想,但 RCR 预测结果优于 Poly3,后者偏差较大;而本文方法与模型 Poly1 和 LWP 一样的退化阶段 2 在线测量数据,同时实现了 2 个退化阶段的局部、长期趋势较准确预测。

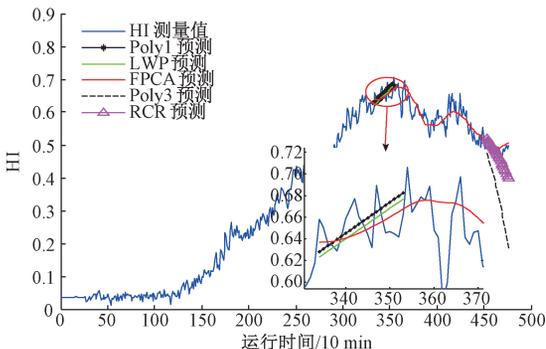


图8 图3(b)散热风扇 HI 的退化预测
Fig.8 Degradation prediction of the cooling fan HI in Fig. 3 (b)

为更好地评估各方法的预测效果,以平均绝对百分比误差 (MAPE) 为评价指标,计算如式 (17) 所示,对 4 个风扇 7 个时间点的预测统计结果如表 3 所示。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y'_i|}{y_i} \times 100\% \quad (17)$$

式中: y_i 为退化 HI 的测量值; y'_i 为相应的预测值; n 为预测点数。

风扇退化阶段 2 由于较简单,通过线性函数 (Poly1) 在该阶段 3 个时间点的预测均获得较高的预测精度。而在退化阶段 3 各个时间点通过 Poly3 的预测结果,误差较大。特别是风扇退化由阶段 2 进入阶段 3 前期,此时可用于拟合模型的退化数据较少, Poly3 方法的预测误差很大。与 Poly1 结合 Poly3 的分段建模预测相比,基于 LWP 和 RCR 的组合方法可以通过扩散项、随机系数项考虑随机性,从而获得更优的预测效果,但需要事先确定趋势的参数化模型。基于 FPCA 建模与贝叶斯推理的方法自适应地进行 2 阶段退化预测,预测的 MAPE 均在 15% 的范围之内,且除在少数几个时间点外,退化预测的 MAPE 都最小,预测精度更高。可见本文的方法在退化预测精度和可行性方面都更有优势。

通过表 3 还可以看出,随着风扇持续运行 (即失效的临近),基于 FPCA 建模与贝叶斯推理方法的预测结果总体呈现越来越准确的趋势。这是因为本文方法建模时融合了失效风扇退化信息,并利用未失效风扇退化测量值对模型中的函数主元得分进行更新,然后基于更新后的参数开展预测。图 3 (b) 中典型风扇在百分比 p_2 、 p_5 、 p_7 3 个时间点的预测更新结果,如图 9 所示。可以看出,与 p_2 时间点相比, p_5 时间点的退化预测更接近 HI 测量值,同样地 p_7 时间的预测比 p_5 时间点的预测更接近实际测量值。随着未失效设备退化在线测量值的累积,本文方法将获得更准确的结果。

表 3 退化预测的 MAPE 结果比较

Table 3 The MAPE result comparison of degradation prediction

风扇	方法	退化阶段						
		2			3			
1	FPCA	5.69	5.57	3.48	11.00	10.55	7.76	8.46
	M2	10.86	9.19	6.98	3 682	271.0	88.89	18.61
	M3	8.84	13.2	6.84	167.2	94.36	66.15	51.32
2	FPCA	7.89	6.79	1.59	4.74	5.15	3.00	3.89
	M2	11.98	6.77	6.91	145 000	326.0	170.3	25.09
	M3	6.67	7.90	14.4	55.27	4.87	8.58	6.83
3	FPCA	3.02	1.22	0.85	0.88	1.13	1.16	0.17
	M2	6.11	5.45	2.69	378.4	138.3	49.10	28.79
	M3	5.75	14.4	2.64	5.13	6.96	6.04	6.07
4	FPCA	7.07	0.61	0.91	1.03	0.87	1.68	2.52
	M2	6.64	5.82	13.7	731.8	102.9	23.26	11.33
	M3	6.31	6.95	3.79	35.18	13.05	10.72	8.69

注:表中 M2 为 Poly1+Poly3 的方法, M3 为 LWP+RCR 的方法。

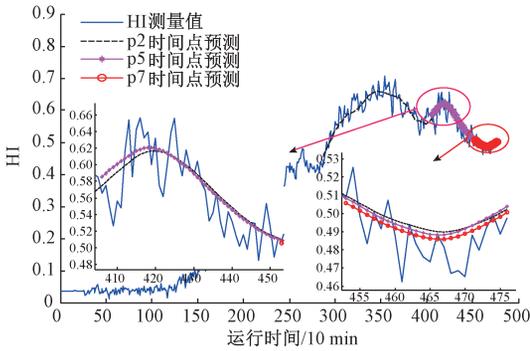


图9 图3(b)散热风扇HI的退化预测更新

Fig.9 Degradation prediction update of the cooling fan HI in Fig. 3 (b)

4 结 论

针对实际中退化过程的多阶段复杂性,从函数型数据分析的视角,本文提出了一种多阶段退化的建模与预测方法。通过对散热风扇寿命数据的验证研究表明,函数主元分析的方法可以自适应地建模其3阶段退化,而且结合贝叶斯推理可对退化预测进行更新。本文方法直接对整个退化过程进行建模,无需识别多阶段退化的变点,也弱化了单阶段退化服从一定参数化模型的假设,具有较好的通用性和潜在工程应用价值。

参考文献

- [1] 雷亚国,贾峰,孔德同,等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Y G, JIA F, KONG D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [2] 刘大同,郭凯,王本宽,等. 数字孪生技术综述与展望[J]. 仪器仪表学报, 2018, 39(11): 1-10.
LIU D T, GUO K, WANG B K, et al. Summary and perspective survey on digital twin technology[J]. Chinese Journal of Scientific Instrument, 2018, 39(11): 1-10.
- [3] LU C J, MEEKER W Q. Using degradation measures to estimate a time-to-failure distribution[J]. Technometrics, 1993, 35(2): 161-174.
- [4] GEBRAEEL N Z, LAWLEY M A, LI R, et al. Residual-life distributions from component degradation signals: A Bayesian approach[J]. IIE Transactions, 2005, 37(6): 543-557.
- [5] WU J, WU CH Y, CAO SH, et al. Degradation data-

driven time-to-failure prognostics approach for rolling element bearings in electrical machines [J]. IEEE Transactions on Industrial Electronics, 2019, 66(1): 529-539.

- [6] ZHAND ZH X, SI X SH, HU CH H, 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.
- [7] LI J X, WANG ZH H, ZHANG Y B, et al. Degradation data analysis based on a generalized Wiener process subject to measurement error [J]. Mechanical Systems and Signal Processing, 2017, 94: 57-72.
- [8] 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 X H, LI J H, SUN Y. Bearing remaining useful life prediction based on two-dimensional wiener process [J]. Chinese Journal of Scientific Instrument, 2018, 39(6): 89-95.
- [9] VAN NOORTWIJK J M. A survey of the application of Gamma processes in maintenance [J]. Reliability Engineering & System Safety, 2009, 94(1): 2-21.
- [10] YE ZH SH, XIE M. Stochastic modelling and analysis of degradation for highly reliable products [J]. Applied Stochastic Models in Business and Industry, 2015, 31(1): 16-32.
- [11] HUANG Z Y, XU ZH G, WANG W H, et al. Remaining useful life prediction for a nonlinear heterogeneous wiener process model with an adaptive drift [J]. IEEE Transactions on Reliability, 2015, 64(2): 687-700.
- [12] 郑建飞,胡昌华,司小胜,等. 考虑不确定测量和个体差异的非线性随机退化系统剩余寿命估计[J]. 自动化学报, 2017, 43(2): 259-270.
ZHENG J F, HU CH H, SI X SH, et al. Remaining useful life estimation for nonlinear stochastic degrading systems with uncertain measurement and unit-to-unit variability [J]. Acta Automatica Sinica, 2017, 43(2): 259-270.
- [13] ZHOU R R, SERBAN N, GEBRAEEL N. Degradation modeling applied to residual lifetime prediction using functional data analysis [J]. The Annals of Applied Statistics, 2011, 5(2B): 1586-1610.
- [14] CHENG Y J, LU CH, LI T Y, et al. Residual lifetime prediction for lithium-ion battery based on functional principal component analysis and Bayesian approach [J].

- Energy, 2015, 90: 1983-1993.
- [15] 鄢伟安, 宋保维, 段桂林, 等. 基于两阶段维纳退化过程的液力耦合器可靠性评估[J]. 系统工程与电子技术, 2014, 36(9): 1882-1886.
YAN W AN, SONG B W, DUAN G L, et al. Reliability evaluation of LCD based on two-phase Wiener degradation process[J]. Systems Engineering and Electronics, 2014, 36(9): 1882-1886.
- [16] WANG P P, TANG Y C, BAE S J, et al. Bayesian analysis of two-phase degradation data based on change-point Wiener process [J]. Reliability Engineering and System Safety, 2018, 170: 244-256.
- [17] WANG Y, PENG Y ZH, ZI Y Y, et al. A two-stage data-driven-based prognostic approach for bearing degradation problem[J]. IEEE Transactions on Industrial Informatics, 2016, 12(3): 924-932.
- [18] 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.
- [19] LEI Y G, LI N P, GUO L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction [J]. Mechanical Systems and Signal Processing, 2018, 104: 799-834.
- [20] 李娟, 景博, 焦晓璇, 等. 基于 LSTAR 的机载燃油泵多阶段退化建模[J].北京航空航天大学学报, 2017, 43(5): 880-886.
LI J, JING B, JIAO X X, et al. Multi-stage degradation modeling for airborne fuel pump based on LSTAR [J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(5): 880-886.
- [21] WEN Y X, WU J G, YUAN Y. Multiple-phase modeling of degradation signal for condition monitoring and remaining useful life prediction[J]. IEEE Transactions on Reliability, 2017, 66(3): 924-938.
- [22] WANG J L, CHIOU J M, MÜLLER H G. Functional data analysis [J]. Annual Review of Statistics and Its Applications, 2016, 3: 257-295.
- [23] YAO F, MÜLLER H G, WANG J L. Functional data analysis for sparse longitudinal data [J]. Journal of the American Statistical Association, 2005, 100 (470): 577-590.
- [24] GUO J Y, LI Y F, ZHENG B, et al. Bayesian degradation assessment of CNC machine tools considering unit non-homogeneity[J]. Journal of Mechanical Science and Technology, 2018, 32(6): 2479-2485.

作者简介



张彬(通信作者),2010年于北京科技大学获得学士学位,2016年于北京科技大学硕博连读获得博士学位,现为重庆邮电大学讲师,主要研究方向为退化过程建模、剩余寿命预测与可靠性分析。

E-mail: zhang825105@126.com

Zhang Bin (Corresponding author) received his B. Sc. degree in 2010 from University of Science and Technology Beijing (USTB), and received his Ph. D. degree in 2016 in a master-doctor joint program also from USTB. Now, he is a lecturer in Chongqing University of Posts and Telecommunications. His main research interests include degradation process modeling, remaining useful life prediction and reliability analysis.