

基于融合特征与数模联动的轴承寿命预测方法*

王前¹, 黄强², 江星星², 徐坤³, 朱忠奎²

(1. 苏州城市学院光学与电子信息学院 苏州, 215104)

(2. 苏州大学轨道交通学院 苏州, 215131)

(3. 南京航空航天大学能源与动力学院 南京, 210016)

摘要 针对现有数模联动剩余使用寿命(remaining useful life, 简称RUL)预测方法易受随机噪声干扰、没有考虑轴承的退化特性等问题,提出了一种基于融合指标与数模联动的轴承RUL预测方法,以提高原始数模联动RUL预测方法的准确性。首先,利用主成分分析及指数加权移动平均算法融合表征轴承退化状态的多种特征,构建单调趋势良好的性能退化融合指标;其次,基于 3σ 准则建立一种首次预测时间确定方案,以触发RUL预测模型的启动,避免RUL预测的无效性;最后,考虑轴承的退化特性,嵌入Rauch-Tung-Striebel平滑滤波算法,以减小退化模型的随机波动,实现轴承RUL的可靠预测。仿真数据和试验信号分析结果证明了所提方法的有效性,相较于现有数模联动方法,显著提高了轴承RUL的预测精度。

关键词 剩余寿命预测;数模联动;滚动轴承;融合特征;平滑滤波

中图分类号 TH133.3;TN713

引言

轴承作为机械设备动力系统的核心部件之一,长期运行在服役环境中,不可避免地出现疲劳损伤、应力破坏等性能退化情况,影响机械设备的运行安全^[1-2]。有效的轴承RUL预测方法有利于制定合理的检修策略,减小维护成本,降低故障风险,确保机械设备安全、稳定和可靠地运行^[3]。RUL预测方法相关理论大致分为2类:物理模型方法和数据驱动方法。物理模型方法主要是通过故障机制或损伤第1原理的基础上,建立数学模型来描述机械的退化过程^[4]。对于一些复杂的机械系统,很难描述损伤原理,从而限制了该方法的发展。数据驱动方法根据被观测对象的性能退化规律,利用随机过程模型或机器学习方法来实现RUL的预测,其主要框架包括性能退化表征指标设计与预测模型构建^[5]。

性能退化表征指标设计,即对轴承的退化过程进行描述,以表征轴承的退化规律。目前,除了单一测度作为退化表征指标外,融合指标设计是指标设计的研究热点,其通过融合算法如主成分分析(principal component analysis, 简称PCA)、独立成分分

析和流形学习^[6]等,融合多个特征实现降维,可以去除冗余信息,捕获更全面的健康状况信息。

根据预测方式不同,预测模型可分为基于机器学习的预测模型和数模联动RUL预测模型。基于机器学习的预测模型利用海量观测数据构建一种非线性模型,而不是建立物理模型或统计模型^[7],可以处理复杂系统的预测问题,但由于缺乏透明度,机器学习方法的结果很难解释,无法量化RUL预测的不确定性。数模联动RUL预测模型是一种利用历史数据和当前数据不断更新退化模型而提供精确的RUL条件概率密度函数(probability density function, 简称PDF)的方法。RUL估计的根本问题是找到其PDF,数模联动方案很好地解决了该问题。

在数模联动RUL预测方法中,需要用特定的退化模型来描述轴承的退化过程,通过历史和当前数据不断更新模型参数。目前,Wiener指数模型是流行的退化模型之一,被广泛用于描述轴承的退化过程^[8]。基于实时监测数据,该模型通过贝叶斯法则更新模型参数,此后在RUL预测中又出现了指数模型的许多变体。Si等^[9]结合贝叶斯法则和期望最大化(expectation maximum, 简称EM)算法进行参数

* 国家自然科学基金资助项目(52172406);中国博士后科学基金资助项目(2021M702752);苏州市重点产业技术创新资助项目(SYG202111);江苏省高等学校自然科学研究资助项目(20KJB460006);运输车辆检测、诊断与维修技术交通行业重点实验室开放基金项目(JTZL2104)

收稿日期:2022-05-20;修回日期:2022-07-10

估计,给出了闭合形式RUL的PDF。现有研究表明,Wiener指数模型可很好地预测具有类指数退化过程系统的RUL,但该模型仍有不足之处:①首次预测时间(first predicting time,简称FPT)没有合理设置;②预测精度易受随机波动的影响。

轴承退化过程大致分为两阶段:健康阶段和非健康阶段^[10]。健康阶段无需进行RUL预测,一旦故障发生,退化指标开始随着故障的加重而以指数形式增加,即在轴承退化开始后进行RUL预测才有意义。触发预测的时间点被称为FPT。FPT的选择对于RUL预测极为重要。如果选择了不适当的FPT,则会包含过多的干扰噪声,影响预测模型的参数估计精度。因此,需设计合理的FPT选择方案以准确地进行轴承预测工作。Wiener指数模型的另一个缺点是受随机波动影响降低RUL预测精度。随机过程一般由趋势项和随机项组成。随机波动与预测结果之间的偏差存在明显的负相关。

从确定FPT以及去除随机过程中的随机干扰角度出发,笔者提出了一种基于融合指标与数模联动的轴承RUL预测方法。首先,从轴承振动信号中提取多种统计特征,利用PCA提取特征集的第1主元,结合指数加权移动平均(exponentially weighted moving average,简称EWMA)算法构建轴承性能退化融合指标来描述轴承的退化过程;其次,基于 3σ 准则确定FPT,启动轴承的预测过程;最后,嵌入Rauch-Tung-Striebel(RTS)平滑滤波算法去除退化模型中的随机噪声,提升数模联动预测的准确性。

3) 估计确定性参数。一旦获取到新的数据 s_k ,需对 θ 和 β 的后验分布进行更新。在更新之前,还需要利用EM算法估计未知参数 $\Theta = [\sigma^2, \mu_0, \sigma_0^2, \mu_1, \sigma_1^2]$ 。在第 i 步时,确定性参数估计假设为 $\hat{\Theta}_k^{(i)} = [\hat{\sigma}_k^{2(i)}, \hat{\mu}_{0,k}^{(i)}, \hat{\sigma}_{0,k}^{2(i)}, \hat{\mu}_{1,k}^{(i)}, \hat{\sigma}_{1,k}^{2(i)}]$,则对数似然函数为 $\ln p(S_{1:k}, \theta, \beta | \Theta_k) = \ln p(S_{1:k} | \theta, \beta, \Theta_k) + \ln p(\theta, \beta | \Theta_k)$,进一步得到似然函数 $\ln p(S_{1:k}, \theta, \beta | \Theta_k)$ 的期望 $\ell(\Theta_k | \hat{\Theta}_k^{(i)})$ 。令 $\partial \ell(\Theta_k | \hat{\Theta}_k^{(i)}) / \partial \Theta_k = 0$,获取期望极值,得到第 $i+1$ 步确定性参数的估计。

4) RUL预测。假设 ω 为预定阈值,则时间 t_k 时

1 Wiener指数退化预测模型

Wiener指数退化模型 $X(t)$ 一般表示为

$$X(t) = \varphi + \theta' \exp(\beta' t + \sigma B(t) - \sigma^2 t/2) \quad (1)$$

其中: φ 为运行工况相关的常数; σ 为随机波动的确定性参数; θ' 和 β' 为轴承退化过程个体差异的随机参数; $B(t)$ 为退化过程中随机动态的标准布朗运动。

$B(t_k) - B(t_{k-1})$ 为独立高斯随机变量,服从分布 $N(0, t_k - t_{k-1})$ 。式(1)的对数化线性模型为

$$S(t) = \theta + \beta t + \sigma B(t) \quad (2)$$

其中: $\theta = \ln \theta'$; $\beta = \beta' - \sigma^2/2$; θ, β 和 σ 独立分布。

Wiener指数退化模型的参数估计和轴承RUL预测实现步骤^[9]如下。

1) 确定 θ, β 参数的先验分布。将 θ 和 β 的先验分布确定为高斯分布: $\theta \sim N(\mu_0, \sigma_0^2)$, $\beta \sim N(\mu_1, \sigma_1^2)$,其中: $\mu_0, \mu_1, \sigma_0^2, \sigma_1^2, \sigma$ 为确定性参数。一旦新的状态监测数据可用,则通过贝叶斯法则确定 θ 和 β 的后验分布,实时更新模型参数。

2) 利用贝叶斯法则更新参数。根据参数 θ 和 β 的先验分布和历史数据得到参数 θ, β 和 σ 的后验分布。 t_k 时刻,基于融合指标 $\mathbf{X}_{1:k} = \{x_1, x_2, \dots, x_k\}$,获得相应的 $\mathbf{S}_{1:k} = \{s_1, s_2, \dots, s_k\}$,其中: $s_k = \ln(x_k)$ 。 θ 和 β 的后验分布分别为

$$\mu_{\theta,k} = \frac{(s_1 \sigma_0^2 + \mu_0 \sigma^2 t_1)(\sigma^2 + \sigma_1^2 t_k) - \sigma_0^2 t_1 (\sigma_1^2 s_k + \mu_1 \sigma^2 - 0.5 \sigma^4)}{(\sigma_0^2 + \sigma^2 t_1)(\sigma_1^2 t_k + \sigma^2) - \sigma_0^2 \sigma_1^2 t_1} \quad (3)$$

$$\mu_{\beta,k} = \frac{(s_k \sigma_1^2 + \mu_1 \sigma^2 - 0.5 \sigma^4)(\sigma_0^2 + \sigma^2 t_1) - \sigma_1^2 (\sigma_0^2 s_1 + \mu_0 \sigma^2 t_1)}{(\sigma_0^2 + \sigma^2 t_1)(\sigma_1^2 t_k + \sigma^2) - \sigma_0^2 \sigma_1^2 t_1} \quad (4)$$

的RUL定义为退化模型首次超过阈值线的时间。 t_k 时刻的RUL估计为

$$E(L_k | \mathbf{S}_{1:k}) = (\omega - s_k) / \mu_{\beta,k} \quad (5)$$

2 所提融合特征与数模联动预测方法

2.1 性能退化融合指标构建

轴承振动信号中蕴含着丰富的退化信息,从中获取描述轴承退化过程的故障敏感特征十分关键^[11]。振动信号的多种时域特征和频域特征可以从不同角度反应轴承的性能退化。提取常见的4种时域特征(标准差、均方根、绝对均值及根均的平方)和

2种频域特征(频域均值及其包络谱均值)作为轴承的性能退化敏感特征。

由于轴承退化过程中各个特征的敏感度不同,单一指标往往不足以全面表征轴承性能退化,因此构建融合指标来有效地揭示轴承的性能退化。笔者使用PCA算法从多维敏感特征中获取融合指标,提取最大特征值对应的特征向量作为初步融合指标。融合后的指标保持了全局单调性,但也包含一些局部随机波动,稳定性和单调性表现不足。为了消除局部波动,保持长期趋势并有效地捕获突变,利用EWMA^[12]平滑技术处理时间序列,其计算式为

$$\begin{cases} x'_t = x_t & (t=1) \\ x'_t = \alpha x_t + (1-\alpha)x'_{t-1} & (t \geq 2) \end{cases} \quad (6)$$

其中: x_t 为 t 时刻当前观测值; x'_t 为其估计值; α 为衡量当前观测值与历史观测值贡献度的平滑参数,取值通常在0.05~0.25之间^[11],本研究 α 取0.2。

图1为轴承融合指标构建流程图。

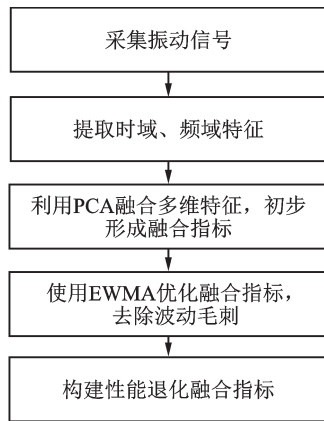


图1 轴承融合指标构建流程图

Fig.1 Flowchart of fusion indicator construction

2.2 FPT 确定策略

为确定合适的FPT,建立了一种基于 3σ 准则的FPT选择方法,以启动轴承的预测过程。首先,利用轴承早期运行阶段的健康数据,计算性能退化融合指标的平均值 μ 和标准差 σ ,确定 3σ 区间 $[\mu - 3\sigma, \mu + 3\sigma]$;然后,利用 3σ 区间识别轴承实时状态。将实时获取的性能退化融合指标与 3σ 区间进行比较,如果指标超过 3σ 间隔,则认为状态异常,轴承可能出现退化行为,将此点记作 t_{FPT} 。但是,轴承性能退化融合指标所表示的异常行为可能是由随机噪声引起,为避免随机噪声的扰动,判断后续5个性能退

化融合指标 $\{D\}_{\text{FPT}, \text{FPT}+5}$ 是否满足 $|D - \mu| \geq 3\sigma$ 。如果满足要求,则 t_{FPT} 为预测首次时间预测点,触发预测过程;反之,判断下一个时刻点性能退化融合指标是否满足FPT的确定条件。

2.3 RTS平滑滤波嵌入策略

轴承振动信号通常伴有随机噪声与测量误差,严重影响数模联动RUL预测方法的稳定性和准确性。为此提出嵌入RTS平滑滤波算法,以减少预测模型中的随机噪声,提升预测精度。

RTS平滑滤波算法是一种系统状态估计的平滑算法,包含前向滤波和后向递推2个步骤。其中,前向滤波的过程与卡尔曼滤波算法一致,而后向递推可以进一步减少估计结果的波动^[13]。

线性动态系统中过程方程和测量方程分别为

$$x_k = Ax_{k-1} + Bu_k + w_k \quad (7)$$

$$z_k = Hx_k + v_k \quad (8)$$

其中: x_k 为系统在 t_k 时刻的状态; z_k 为 t_k 时刻的测量值; u_k 为控制变量向量; B 为对应的系数矩阵; A 为状态转移矩阵; H 为观测矩阵; w_k 和 v_k 为过程噪声和测量噪声,其服从高斯分布 $w_k \sim N(0, Q)$ 和 $v_k \sim N(0, R)$; Q 和 R 为对应的协方差。

2.3.1 前向滤波

通过预测的状态值与实际测量值的加权平均形成一个关于当前状态准确的估计

$$m'_k = A_k m_{k-1} + B_k u_k \quad (9)$$

$$P'_k = A_k P_{k-1} A_k^T + Q_k \quad (10)$$

$$K_k = P'_k H_k^T (H_k P'_k H_k^T + R_k)^{-1} \quad (11)$$

$$m_k = m'_k + K_k (z_k - H_k m'_k) \quad (12)$$

$$P_k = (I - K_k H_k) P'_k \quad (13)$$

其中: m_{k-1} 为 t_{k-1} 时刻的最优估计; m'_k 为 t_k 时刻系统状态的初始预测; P'_k 为 t_k 时刻初始估计的协方差矩阵; P_{k-1} 为 t_{k-1} 时刻最优估计的协方差矩阵; K_k 为卡尔曼增益; m_k 为 t_k 时刻的最优估计。

2.3.2 后向递推

前向滤波结束后,利用前向滤波产生的最优估计 m_k 与协方差矩阵 P_k 进行逆向递推。最后 t_k 时刻获得的状态估计矩阵 m_k 和协方差矩阵 P_k 即为后向递推过程的初始状态估计 m_k^s 与协方差矩阵 P_k^s 。

RTS平滑滤波算法嵌入基于Wiener过程的指数退化模型中,必须建立合适的过程方程和测量方程。此外,过程噪声和测量噪声的量化应接近监测

数据中的实际随机噪声。基于 Wiener 过程的指数模型结构, t_k 时刻的对数退化模型可表示为

$$s_k = s_{k-1} + \mu_{\beta,k} \Delta t + \varepsilon + \sigma G(t_{k-1}) \quad (14)$$

其中: ε 为方差是 $\Delta t^2 \sigma_{\beta,k}^2$ 的高斯分布变量; 根据布朗运动的性质, $G(t_{k-1})$ 服从布朗运动, $\sigma G(t_{k-1})$ 为方差是 $\Delta t^2 \sigma^2$ 的高斯分布变量。

将式(14)变换为过程方程和测量方程形式, 建立一个具有标准高斯分布噪声的线性动力系统

$$s_k = s_{k-1} + \mu_{\beta,k} \Delta t + \varepsilon \quad (15)$$

$$z_k = s_k + \tau \quad (16)$$

其中: ε 为过程噪声, $\varepsilon \sim N(0, \Delta t^2 \sigma_{\beta,k}^2)$; τ 为测量噪声, $\tau \sim N(0, \Delta t^2 \sigma^2)$ 。

随着更新, 可以实时获取退化模型的当前测量值, 基于贝叶斯法则求出 t_k 时刻的 $\mu_{\beta,k}$, $\sigma_{\beta,k}^2$ 和 σ^2 。根据嵌入 RTS 平滑滤波算法获得 Wiener 指数模型当前时刻的最优估计, 实现过程噪声与测量噪声的去除。

2.4 基于融合特征与数模联动的预测方法

提出的数模联动轴承 RUL 预测方法具体如下。

1) 针对采集到的振动信号构建性能退化融合指标。选取轴承早期历史数据作为健康数据, 提取这一时期内指标的平均值 μ 和标准差 σ , 执行 FPT 确定策略, 启动 RUL 预测过程。

2) 预测模型参数初始化。在初始时刻 t_0 , 模型初始化参数为 $\mu_0 = \mu_{\theta,0}$, $\sigma_0^2 = \sigma_{\theta,0}^2$, $\mu_1 = \mu_{\beta,0}$, $\sigma_1^2 = \sigma_{\beta,0}^2$, $\sigma^2 = \sigma_0^2$, 其中: $\mu_{\theta,0}$ 和 $\mu_{\beta,0}$ 可根据初始时刻的性能退化融合指标 s_0 和 s_1 确定, $\mu_{\theta,0} = s_0$, $\mu_{\beta,0} = (s_1 - s_0)/t_1$; $\sigma_{\theta,0}^2$ 和 $\sigma_{\beta,0}^2$ 可以随机初始化, 远小于 $\mu_{\theta,0}$ 和 $\mu_{\beta,0}$ 即可。

3) 使用贝叶斯法则和 EM 算法更新状态模型的参数。在 t_k 时刻 ($k \geq 1$) 获得新的性能退化融合指标 s_k , 令 $\sigma^2 = \sigma_{k-1}^2$, $\mu_0 = \mu_{\theta,k-1}$, $\sigma_0^2 = \sigma_{\theta,k-1}^2$, $\mu_1 = \mu_{\beta,k-1}$, $\sigma_1^2 = \sigma_{\beta,k-1}^2$, 更新参数 $\mu_{\theta,k}$, $\sigma_{\theta,k}^2$, $\mu_{\beta,k}$ 和 $\sigma_{\beta,k}^2$ 。使用 EM 算法估计参数 σ^2 , μ_0 , σ_0^2 , μ_1 和 σ_1^2 , 获得下一时刻更新的确定性参数。

4) 嵌入 RTS 平滑滤波算法去除模型中的噪声。一旦获得时刻 t_k 的参数估计值 $\mu_{\beta,k}$, $\sigma_{\beta,k}^2$ 和 σ_k^2 , 则系统的过程噪声和测量噪声可以分别定义为 $\varepsilon \sim N(0, \Delta t^2 \sigma_{\beta,k}^2)$ 和 $\tau \sim N(0, \Delta t^2 \sigma_k^2)$, 利用 RTS 平滑滤波算法估计系统状态 \hat{s}_k 。

5) 计算轴承 RUL 估计及其概率密度函数。

3 仿真与案例分析

3.1 仿真数据分析

为了验证模型参数估计的准确性, 根据轴承的退化特性构造类指数随机时间序列。构造仿真序列为

$$C(t) = \exp(\theta + \beta t + \sigma B(t)) \quad (17)$$

其中: θ 和 β 服从高斯分布; $\theta \sim N(\mu_0, \sigma_0^2)$; $\beta \sim N(\mu_1, \sigma_1^2)$; t 取 $[1:500]$, 表示这段序列共有 500 个数据点。

表 1 为仿真数据参数值。图 2 为仿真数据随时间变化曲线波形。由于构造的随机序列从第 1 个点开始就符合指数退化趋势, 故将第 1 个时间点作为 FPT, 直接启动预测过程。

表 1 仿真数据参数值

Tab.1 Values of parameters used for simulated data

参数	μ_0	σ_0^2	μ_1	σ_1^2	σ
数值	0.014	1×10^{-8}	0.006	1×10^{-9}	0.03




图 2 仿真数据随时间变化曲线波形

Fig.2 Waveform of simulated data with the change of time

确定性参数估计如图 3 所示。在初始阶段, 参数 μ_0 , μ_1 和 σ 的估计值与实际值相差很大, 在获取到足够多的信息后, 参数估计值逐渐收敛于实际值。这表明初始参数值的选择对最终预测结果的影响不大, 模型稳健性好。




图 3 确定性参数估计

Fig.3 Estimation of deterministic parameters

仿真数据建模如图 4 所示。可见, 所提方法可以有效地减小轴承退化曲线中随机噪声的影响, 提高了 RUL 预测精度。




图4 仿真数据建模

Fig.4 Degradation modeling of the simulated data

仿真数据的预测结果与预测误差如图5所示。初始预测阶段由于缺乏数据,2种方法的预测结果不准确、不稳定。随着实时信息的获取,模型的状态信息变多,预测结果越来越准确。随着RTS平滑滤波算法的嵌入,随机噪声得到抑制,所提方法的精度和稳定性相较于原始方法更优。以上分析表明,所提方法能够很好地跟踪轴承的退化轨迹,实现RUL预测。




图5 仿真数据的预测结果与预测误差

Fig.5 Result and error of RUL prediction with simulated data

为了评价2种方法的预测误差,引入4个误差指标^[13]:平均绝对相对误差(mean absolute relative error,简称MARE)、得分(SCORE)、平均绝对误差(mean absolute error,简称MAE)和均方根误差(root mean square error,简称RMSE)。4种误差函数的计算式为

$$MARE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y'_i}{y_i} \right| \times 100\% \quad (18)$$

$$SCORE = \begin{cases} \sum_{i=1}^N \left[\exp\left(-\frac{(y'_i - y_i)}{10}\right) - 1 \right] & (y'_i < y_i) \\ \sum_{i=1}^N \left[\exp\left(\frac{(y'_i - y_i)}{13}\right) - 1 \right] & (y'_i > y_i) \end{cases} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - y'_i| \quad (20)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (21)$$

其中: y_i 为RUL真实值; y'_i 为RUL预测值。

若RUL预测值与实际值存在较大的偏差,则MARE,SCORE,MAE和RMSE的值都会偏高。

忽略预测开始阶段历史数据不足对方法的影响,将预测过程的后一半预测结果代入式(18)~(21)进行比较。仿真数据下预测模型性能对比如表2所示。可以看出,所提方法相对于原始方法预测误差较小,进一步说明所提方法的优越性。

表2 仿真数据下预测模型性能对比

Tab.2 Performance comparison of prediction model with simulated data

方法	SCORE	MARE	MAE	RMSE
原始方法	0.235 4	0.319 1	20.23	24.99
改进方法	0.004 4	0.139 0	12.71	14.87

3.2 案例分析

利用文献[14]提供的轴承全寿命试验数据来验证提出方法的有效性。轴承全寿命试验平台^[14]如图6所示。该平台是专门为轴承故障检测、诊断和预测而设计的,能够在几小时内模拟轴承的加速退化过程。振动加速度传感器固定在测试轴承上方,用来采集振动信号。当振动信号的振幅超过20 g时,试验台停止运行。试验中,测试轴承型号为6804DU,采样频率为25.6 kHz,每10 s重复采样一次,每次采样时间为0.1 s。




图6 轴承全寿命试验平台

Fig.6 Test rig of bearing run-to-failure

选取编号为轴承1_1和轴承1_3的数据集来检验所提方法的有效性。图7为2组轴承振动信号的时域波形。可以看出,轴承的运行过程分为2个阶段。在健康阶段,振动信号相对稳定,波动幅度较小;在非健康阶段,振动信号的幅值呈逐渐增大的趋势。利用所提方法依次对2组轴承振动信号进行分析。

1) 构建轴承性能退化融合指标,确定轴承预测过程启动的首次预测时间点。2组轴承振动信号的

FPT 确定结果如图 8 所示,在时间为 13 970 s 和 13 270 s 时分别检测轴承 1_1 和 1_3 的 FPT。

2) 使用改进的数模联动方法对其开始预测。将性能退化融合指标的最后 3 个点的平均值作为故障阈值终止预测过程。2 组轴承的退化建模如图 9 所示。可以看出,RTS 平滑滤波抑制了性能退化融合指标中的噪声,进一步提升了预测的准确性。2 组轴承的 RUL 预测结果和预测误差如图 10,11 所示,可以看出所提方法存在优势。图 12 为 2 组轴承 RUL 的 PDF,给出了轴承从 1 600 s 开始每隔 700 s RUL 预测的概率密度函数,可以看出提出方法的预测曲线能够较好覆盖 RUL 真实值。




图 7 2组轴承振动信号的时域波形

Fig.7 Time waveforms of two group of bearing vibration signals




图 8 2组轴承振动信号的FPT 确定结果
Fig.8 FPT decision results of two bearings




图 9 2组轴承的退化建模
Fig.9 Degradation modeling of two bearings

2 组轴承预测结果对比如表 3 所示,进一步验证了所提方法 RUL 预测的优越性。

表 3 2组轴承预测结果对比

Tab.3 Comparison of prediction with two bearings

方法	SCORE		MARE		MAE		RMSE	
	轴承 1_1	轴承 1_3	轴承 1_1	轴承 1_3	轴承 1_1	轴承 1_3	轴承 1_1	轴承 1_3
原始方法	65.35	13.24	0.663 3	0.716 7	128.6	66.24	152.3	85.48
改进方法	0.754 6	3.436	0.389 2	0.493 1	102.1	42.23	117.9	52.17




图 10 2组轴承的 RUL 预测结果

Fig.10 RUL prediction results of two bearings




图 11 2组轴承的 RUL 预测误差

Fig.11 RUL prediction errors of two bearings




图 12 2组轴承 RUL 的 PDF

Fig.12 PDFs of RUL for two bearings

4 结论

1) 通过 PCA 和 EWMA 算法构建了单调趋势良好的性能退化融合指标,充分挖掘轴承的退化状态信息,克服了单一状态表征指标的局限性,提升指标的轴承退化表征性能。

2) 考虑轴承的退化特性,基于 3σ 准则建立 FPT 确定方法,以启动轴承的预测过程,避免 RUL 预测的无效性。将 RTS 平滑滤波算法嵌入到 Wiener 指数退化模型中去随机波动,抑制随机噪声干扰,提高了 RUL 的预测精度。

3) 提出了一种基于融合指标与数模联动的轴承 RUL 预测方法,相较于现有数模联动方法,显著提高了轴承 RUL 的预测精度,实现 RUL 的可靠预测。仿真数据和全寿命试验结果表明,所提方法预

测结果的4个误差评价函数值均小于原始预测方法的预测结果,预测精度得到了提升。

参 考 文 献

- [1] 何正嘉,曹宏瑞,訾艳阳,等. 机械设备运行可靠性评估的发展与思考[J]. 机械工程学报, 2014, 50(2): 171-186.
HE Zhengjia, CAO Hongrui, ZI Yangyang, et al. Developments and thoughts on operational reliability assessment of mechanical equipment[J]. Journal of Mechanical Engineering, 2014, 50(2): 171-186. (in Chinese)
- [2] 张旭辉,张超,樊红卫,等. 快速谱峭度结合阶次分析滚动轴承故障诊断[J]. 振动、测试与诊断, 2021, 41(6): 1090-1095.
ZHANG Xuhui, ZHANG Chao, FAN Hongwei, et al. Improved fault diagnosis of rolling bearing by fast kurtogram and order analysis[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(6): 1090-1095. (in Chinese)
- [3] LEE J, WU F, ZHAO W, et al. Prognostics and health management design for rotary machinery systems: reviews, methodology and applications [J]. Mechanical Systems and Signal Processing, 2014, 42(1/2): 314-334.
- [4] CUBILLO A, PERINPANAYAGAM S, ESPERONMIGUEZ M. A review of physics-based models in prognostics: application to gears and bearings of rotating machinery [J]. Advances in Mechanical Engineering, 2016, 8(8): 1-21.
- [5] LEI Y, LI N, 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.
- [6] MA M, CHEN X, ZHANG X, et al. Locally linear embedding on grassmann manifold for performance degradation assessment of bearings [J]. IEEE Transactions on Reliability, 2017, 66(2): 467-477.
- [7] 王玉静,李少鹏,康守强,等. 结合CNN和LSTM的滚动轴承剩余使用寿命预测方法[J]. 振动、测试与诊断, 2021, 41(3): 439-446.
WANG Yujing, LI Shaopeng, KANG Shouqiang, et al. Method of predicting remaining useful life of rolling bearing combining CNN and LSTM[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(3): 439-446. (in Chinese)
- [8] 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.
- [9] SI X, WANG W, CHEN M, et al. A degradation path-dependent approach for remaining useful life estimation with an exact and closed-form solution [J]. European Journal of Operational Research, 2013, 226(1): 53-66.
- [10] YAN B, MA X, HUANG G, et al. Two-stage physics-based Wiener process models for online RUL prediction in field vibration data [J]. Mechanical Systems and Signal Processing, 2021, 152: 107378.
- [11] 刘涛,梁成玉. 信息熵融合的PSO-SVC涡旋压缩机故障诊断[J]. 振动、测试与诊断, 2022, 42(1): 141-147.
LIU Tao, LIANG Chengyu. PSO-SVC fault diagnosis of scroll compressor based on information entropy fusion [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(1): 141-147. (in Chinese)
- [12] LI X, JIANG H, XIONG X, et al. Rolling bearing health prognosis using a modified health index based hierarchical gated recurrent unit network [J]. Mechanism and Machine Theory, 2019, 133: 229-249.
- [13] LI Y, HUANG X, DING P, et al. Wiener-based remaining useful life prediction of rolling bearings using improved Kalman filtering and adaptive modification [J]. Measurement, 2021, 182: 109706.
- [14] NECTOUX P, GOURIVEAU R, MEDJAHER K, et al. Pronostia: an experimental platform for bearings accelerated degradation tests [C]//IEEE International Conference on Prognostics and Health Management. Denver, Colorado: [s. n.], 2012: 1-8.



第一作者简介:王前,女,1991年3月生,硕士、讲师。主要研究方向为风电装备设计制造与智能运维。曾发表《Synchronous chirp mode extraction: a promising tool for fault diagnosis of rolling element bearings under varying speed conditions》(《Chinese Journal of Aeronautics》, 2022, Vol. 35, No.1)等论文。
E-mail:wangqian_sdzwz@163.com

通信作者简介:江星星,男,1989年11月生,副教授、硕士生导师。主要研究方向为非平稳信号处理、状态评估与寿命预测。
E-mail:jiangxx@suda.edu.cn