

非稳态工况下轴承剩余寿命动态预测方法

熊亮¹, 蔺肖曼¹, 曹宏瑞^{1,2}, 朱成³, 胡睿杰³, 李志鹏³, 时大方⁴

(1. 西安交通大学机械工程学院 西安, 710049)

(2. 西安交通大学航空动力系统与等离子体技术全国重点实验室 西安, 710049)

(3. 中国北方发动机研究所 天津, 300400)

(4. 浙江天马轴承集团有限公司 湖州, 313219)

摘要 为了解决轴承在非稳态工况下退化特征难以获取、退化状态识别困难和剩余使用寿命 (remaning useful life, 简称 RUL) 预测精度低等问题, 提出了一种非稳态工况下轴承剩余寿命动态预测方法。首先, 对初始温度信号进行重采样, 削弱因设备维护等操作带来的温度异常波动; 其次, 构建了考虑环境、转速、故障和随机波动的温度变化模型, 通过结合温差变化模型与监测数据中的转速信息, 实现了温差信号的实时解耦, 从而有效提取变工况下轴承温度信号中潜在的退化特征信号; 然后, 采用时变 3σ 准则进行轴承的早期退化监测, 获取轴承退化起始点; 最后, 将 Paris-Erdogan 模型与动态演化模型结合, 实现基于实时监测数据的模型参数实时动态更新, 结合粒子滤波 (particle filter, 简称 PF) 算法输出了 RUL 的近似分布, 利用温差变化状态的预测值与观测值之间的差异, 更新了 RUL 近似分布中粒子的权重, 优化了 RUL 输出结果。采用现场实际设备获取的非稳态工况下的轴承数据进行验证, 结果表明, 所提出方法的精度高于 85%, 且所有结果均在 90% 置信区间内, 验证了该方法的有效性。

关键词 滚动轴承; 温度监测; 非稳态工况; 动态演化; 剩余寿命预测

中图分类号 TH165.3; TH133.33

0 引言

现代工业领域中, 高端装备的综合化与智能化程度不断提升, 但其运行环境恶劣, 导致维护与保障成本日益增高。由于高端装备组成环节增多、各环节间耦合性增强, 加之运行工况复杂多变, 故障发生概率逐渐上升, 因此重大装备的预测与健康管理 (prognostics and health management, 简称 PHM) 技术逐渐成为研究热点^[1-3]。基于状态监测的剩余寿命预测在维护策略选择与检查优化等方面发挥着重要作用^[4-6]。轴承故障是导致机械设备停机的最常见的故障形式之一^[7]。因此, 通过监测机械设备轴承的实时状态、评估其健康程度并预测剩余使用寿命, 对于制定维护策略愈发重要^[8-10]。

随着传感监测与机器学习技术的快速发展, 数据驱动方法已成为剩余寿命预测的主流。该方法通过学习历史数据中的趋势信息和统计特征, 构建其与部件剩余寿命之间的映射关系。该过程无需明确的失效机理及特定领域知识, 因而成为复杂工况下轴承剩余寿命预测的热门选择。Zhu 等^[11]提出了基

于多层感知机 (multiple layer perceptron, 简称 MLP) 的迁移学习方法实现差异学习。Li 等^[12]在联合分布中引入动态惩罚项, 提升了域自适应的细粒度与预测能力。上述方法多基于跨工况数据验证, 而实际工程中轴承常在变工况下运行。Lu 等^[13]提出利用自校准模块关注时间序列局部信息的改进时间卷积网络, 用于变工况下的轴承剩余寿命预测。Cerrada 等^[14]提出了一种不确定性量化方法, 能在先验知识较少的情况下提供核密度估计和蒙特卡洛随机失活的概率性寿命预测结果, 实现了变工况条件下的轴承剩余寿命预测结果的不确定性量化, 提升了预测结果的可行性。Ren 等^[15]将持续学习方法用于变工况轴承剩余寿命预测, 使网络无需繁琐重训练即可逐步提升性能。

尽管数据驱动方法在少量测试中表现良好, 但其可解释性较差。Gao 等^[16]提出了一种面向多传感器数据的广义预测模型, 采用线性贝叶斯模型对退化信号建模, 并构建 3 层神经网络模拟剩余寿命与多传感器退化数据间的非线性映射关系, 同时利用贝叶斯更新实现模型参数更新。Cao 等^[17]提出了一

种数据与模型联合驱动的预测框架,利用多头注意力转换器提取退化信息,以指数模型作为退化模型,结合扩展卡尔曼滤波器更新退化过程参数,最终通过回归器预测轴承剩余寿命。然而,上述方法仅为数据驱动与模型驱动方法的简单串联,未体现二者之间的深度融合与优化。

现有变工况下轴承剩余寿命预测方法多基于高采样频率的振动信号,对温度信号中的信息挖掘不足。与振动信号相比,温度信号具有良好的抗干扰能力,能在复杂工况下表征轴承退化过程,且更易测量。高端装备监测系统包含长时间跨度的温度数据,可有效获取轴承从正常到故障直至失效的长周期寿命信息^[18]。Hu等^[19]基于温度信号构建了Wiener过程的退化模型,但未给出长时间序列下的预测结果。因此,基于温度信号的轴承剩余寿命预测仍有较大探索空间。

针对轴承退化趋势存在个体差异且受工况变化影响较大的特点,笔者提出一种非稳态工况下数模联合驱动的轴承剩余寿命预测方法,综合考虑转速连续变化及退化过程实时变化的影响。

1 轴承剩余寿命预测方法

轴承的全寿命周期可分为健康、退化与失效3个阶段。图1为轴承全寿命周期示意图。当轴承进入失效阶段时,需及时维护或更换。因此,准确识别失效起始点具有重要的实际意义,剩余寿命预测也从此阶段开始。温度信号抗干扰能力强,且机械

设备监测系统可提供长期轴承温度数据,故笔者采用温度信号进行状态监测与RUL预测。




图1 轴承全寿命周期示意图

Fig.1 Schematic diagram of the whole life cycle of a bearing

轴承剩余寿命预测总体框架如图2所示,包括状态监测与剩余寿命预测2个模块。状态监测模块包含数据重采样、信号解耦与退化特征提取、早期退化监测3个部分。剩余寿命预测模块结合退化模型、动态演化模型和PF算法进行RUL预测。具体流程为:通过状态监测模块提升变工况下轴承数据质量并提取退化特征,基于时变 3σ 原则实现早期退化监测;再利用剩余寿命预测模块实时更新轴承退化状态,输出对应的RUL预测结果。

1.1 状态监测

1.1.1 数据预处理

重大装备在服役期内须周期性地对轴承进行间歇加脂以保证润滑。温度信号作为缓变信号,对冲击性变化不敏感,但定期加脂会改变轴承的工作环境,并影响其散热与放热过程,导致温度信号出现异




图2 轴承剩余寿命预测总体框架

Fig.2 Overall framework of bearing RUL prediction

常。若直接剔除这类偏离数据,会造成轴承数据时间不连续,影响后续预测效果。为此,根据正常先验信息获取均值 μ_n 与标准差 σ_n ,并生成相应的正态随机数进行插值,具体的重采样策略为

$$T_n = \begin{cases} T_n & (T_n < T_{n, \text{initial}}) \\ N(\mu_n, \sigma_n) & (T_n > T_{n, \text{initial}}) \end{cases} \quad (1)$$

其中: T_n 为第 n 个时间步的温度信号; $T_{n, \text{initial}}$ 为根据先验信息确定的温度阈值,用于筛选由环境变化引起的异常数据。

1.1.2 信号解耦和退化特征提取

轴承温度变化的本质在于发热量与散热量之间差值的变化。发热量主要来源于轴承和转子、轴承和箱体之间的摩擦生热,而散热过程较为复杂,其主要受环境温度影响。当轴承发生磨损或碎裂等故障时,其表面质量发生变化,导致发热量显著增加,表现为轴承温度显著上升。综合考虑以上因素,并假设各因素对轴承温度变化的影响相互独立,轴承温度可表示为

$$T = T_{\text{env}}(t) + T_{\text{speed}}(n) + T_{\text{fault}}(\alpha) + \beta(t, n) \quad (2)$$

其中: T 为轴承实测温度信号; $T_{\text{env}}(t)$ 为环境温度变化对轴承温度变化的影响函数; $T_{\text{speed}}(n)$ 为转速变化对轴承温度变化的影响函数; $T_{\text{fault}}(\alpha)$ 为故障因素对轴承温度变化的影响函数; $\beta(t, n)$ 为考虑外界波动引入的随机扰动量。

同一设备不同轴承测点温度的差值表示为

$$\Delta T = \Delta T_{\text{env}}(t) + \Delta T_{\text{speed}}(n) + \Delta T_{\text{fault}}(\alpha) + \Delta \beta(t, n) \quad (3)$$

其中: $\Delta T_{\text{env}}(t)$ 为随时间和空间变化的随机函数。

在同一时空条件下,有 $\Delta T_{\text{env}}(t) = 0$ 。随机波动误差影响较小,在一定的平滑尺度下带来的影响较小,则有 $\beta(t, n) = 0$ 。对于正常设备, $\Delta T_{\text{fault}}(\alpha) = 0$,则得到正常轴承以及故障轴承与正常轴承的温差表达式为

$$\Delta T_{\text{normal}} = \Delta T_{\text{speed}}(n) \quad (4)$$

$$\Delta T_{\text{fault}} = \Delta T_{\text{speed}}(n) + \Delta T_{\text{fault}}(\alpha) \quad (5)$$

根据式(4)、(5)得到

$$\Delta T_{\text{fault}}(\alpha) = \Delta T_{\text{fault}} - \Delta T_{\text{speed}}(n) \quad (6)$$

重大装备运行工况复杂多变,个体差异性强,须对轴承温差函数 ΔT 采用个性化制定策略。将获取的正常轴承与故障轴承的温差数据,按转速从高到低排列,并以固定窗长 L 进行平滑后,发现正常轴承的温差值趋于平稳区间内变化,而故障轴承则呈上升趋势。正常与故障轴承全周期数据按转速重排后的变化趋势如图3所示。其中:B-1和B-2为后期出

现故障的轴承;B-4和B-5为正常轴承。可以发现,当轴承处于正常状态时,温差值和转速几乎无关;而故障状态下,温差值与转速呈正相关。




图3 正常与故障轴承全周期数据按转速重排后的变化趋势
Fig.3 Trend of full-cycle data for normal and faulty bearings rearranged by rotational speed

依托上述温差模型,提出一种温差信号解耦方法,信号解耦的具体流程如下:

1) 选定窗长 L ,将正常历史数据按转速从高到低排列,采用移动平均法对重排数据进行平滑处理。

2) 平滑后的正常历史数据用于建立轴承正常阶段的温差变化模型 ΔT_{normal} ,即

$$\Delta T_{\text{normal}} = \sum_{i=0}^k \alpha_i n^i \quad (7)$$

对参数 $\{a_0, a_1, \dots, a_k\}$ 进行估计,即

$$\min_{\{a_i\}} \sum_{i=1}^k (\Delta T_{\text{normal}}^{(i)} - \Delta T_{\text{normal, model}}^{(i)})^2 \quad (8)$$

其中: $\Delta T_{\text{normal}}^{(i)}$ 为 t 时刻正常状态下与转速相关的轴承实测温差分量; $\Delta T_{\text{normal, model}}^{(i)}$ 为模型拟合值。

3) 由式(6)可得 $\Delta T(\alpha) = \Delta T_{\text{fault}} - \Delta T_{\text{normal}}$,代入式(7),得到 $\Delta T_{\text{fault}}(\alpha) = \Delta T_{\text{fault}} - \sum_{i=0}^k \alpha_i n^i$ 。

4) 在相同窗长下,采用移动平均法对监测温差数据进行平滑处理,基于温差变化模型 $\sum_{i=0}^k \alpha_i n^i$ 与监测的实时转速变量 n ,提取轴承温差信号中的退化特征 $\Delta T_{\text{fault}}(\alpha)$ 。

1.1.3 早期退化监测

轴承正常阶段的持续时间较长,此时温差指标平稳且数值较小,无需进行剩余寿命预测。当轴承进入退化阶段后,发热量增大导致温差值持续上升。因此,准确监测早期退化起始点,并在适当时机

开展剩余寿命预测,既可节约计算资源,又能提高预测精度。

温度信号易受外界干扰而产生局部波动,影响轴承健康状态的准确识别。传统的温度阈值判定方法易受局部波动影响而产生误判。时变 3σ 准则是在 3σ 准则基础上改进的自适应异常检测方法,通过时变均值和方差计算异常阈值^[20]。当健康指标连续多次超过该阈值时,判定设备处于异常状态。相比传统 3σ 准则,时变 3σ 准则具有以下优势:①无需预先假设数据健康状态以固定异常阈值,而是随进程逐步更新阈值;②对小幅短暂变化更为敏感,所需先验知识更少,更适用于工程实际。

时变 3σ 准则的基本流程如图 4 所示。




图 4 时变 3σ 准则流程图

Fig.4 Flowchart of the time-varying 3σ criterion

采用时变 3σ 准则对轴承温度信号进行实时状态监测,可有效降低局部波动干扰。考虑在端点处可能出现极端异常值,取前 t_0 小时的数据计算均值和标准差,作为该时间段的报警阈值基准;对于 t_0 小时之后的数据,采用时变 3σ 准则动态计算阈值,并根据新输入的监测数据实时更新。为了进一步消除随机误差、减少误报,引入多点触发机制判定退化起始点。由于温度信号的动态敏感度较低,因此设定触发条件为:15 d 内超过 50% 的数据点超出阈值时,即判定轴承处于故障状态。

为减少监测过程中的误报现象,采用二次重采样以减小正常数据的波动,其表达式与式(1)相同。

1.2 剩余寿命预测

1.2.1 退化模型

采用 Paris-Erdogan 裂纹扩展模型来描述轴承的退化过程,其表达式为

$$\frac{dx}{dN} = C(\Delta k)^m \quad (9)$$

其中: x 为故障尺寸; N 为疲劳寿命; Δk 为应力强度因子幅值, $\Delta k = F\Delta S\sqrt{\pi x}$; ΔS 为应力幅值; C 、 m 和

F 为材料参数。

轴承温差值与裂纹尺寸近似线性相关,故温差变化可表示为

$$\Delta T = \lambda x \quad (10)$$

其中: λ 为温度值与轴承的相关系数。

Paris-Erdogan 模型中的 C 、 m 、 F 和 ΔS 需通过实验获取,且故障尺寸在运行过程中难以直接测量。因而,对该模型进行简化。令 $\alpha = CF^m\Delta S^m\pi^{m/2}$, $\beta = m/2$, 则得到简化模型为

$$\frac{dx}{dN} = \alpha_0 x^\beta \quad (11)$$

其中: α 和 β 为模型参数。

将式(10)代入式(11),令 $\alpha = \lambda\alpha_0$, 得到轴承温度变化率与故障的关系为

$$\frac{d\Delta T}{dN} = \alpha(\Delta T)^\beta \quad (12)$$

1.2.2 动态演化模型

目前,许多机械设备仍采用定期维修方式,存在大量带“病”运行现象。相比于当前流行的端到端学习方法,利用带“病”轴承的历史退化趋势进行学习,并继续用于该轴承的剩余寿命预测,更契合工程实际。轴承退化过程具有非线性和非高斯特性。动态演化模型基于退化过程中状态与参数随时间的变化规律建立,能够有效描述轴承的动态退化过程及不确定性传播。笔者构建的动态演化模型通过引入观测误差、动态模型参数和随机退化系数,模拟轴承的真实退化过程。

系统的观测值与实际值之间存在观测误差,通过引入近似分布模拟该误差,则温差观测值与实际值的关系为

$$\Delta T_i^{\text{obs}} = \Delta T_i^{\text{true}} + \nu \quad (13)$$

其中: ν 表示观测系统的不确定性; ΔT_i^{obs} 为 i 时刻的温差观测值; ΔT_i^{true} 为 i 时刻的温差真实值。

利用监测过程中的“轻症”数据获取初始模型参数 α 和 β , 实现不同工况下轴承退化模型的个性化定制。为进一步度量退化模型的不确定性,模型参数用近似分布表示为

$$\Theta = (\alpha, \beta) \sim N(\mu_\Theta, \sigma_\Theta^2) \quad (14)$$

其中: Θ 为模型参数 α 和 β 组成的向量。

轴承在退化过程中,模型参数 α 和 β 也会相应变化。贝叶斯学习能够有效融合先验数据与似然信息,实现对后验信息的推理,已被广泛用于不确定性推理问题中^[21]。结合贝叶斯学习方法,利用实时观测数据对模型参数 $\Theta_i = (\alpha_i, \beta_i)$ 进行实时更新,其后验分布可表示为

$$p(\boldsymbol{\theta}|\Delta T_{1:t}^{\text{obs}}) = \frac{p(\boldsymbol{\theta})L(\Delta T_{1:t}^{\text{obs}}|\boldsymbol{\theta})}{\int p(\boldsymbol{\theta})L(\Delta T_{1:t}^{\text{obs}}|\boldsymbol{\theta})d\boldsymbol{\theta}} \quad (15)$$

其中: $p(\boldsymbol{\theta}|\Delta T_{1:t})$ 为给定历史温差观测值后参数的后验概率密度; $p(\boldsymbol{\theta})$ 为参数的先验概率密度; $L(\Delta T_{1:t}|\boldsymbol{\theta})$ 为似然概率,这里选用高斯似然。

$p(\boldsymbol{\theta}|\Delta T_{1:t}^{\text{obs}})$ 难以直接求解,可先设计一个目标分布为 $p(\boldsymbol{\theta}|\Delta T_{1:t}^{\text{obs}})$ 的稳态分布马尔可夫链 $\{\boldsymbol{\theta}_0, \boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_m\}$,通过计算迭代抽样的方式实现对目标分布的近似求解,并以粒子分布的均值作为模型参数的更新结果。

考虑轴承退化过程中的不确定因素,将上一时刻的后验信息作为下一时刻的先验信息,并引入随机变量 ϵ ,从而实现了对轴承退化过程的全面描述,其表达式为

$$\Delta T_t^{\text{true}} = \Delta T_{t-1}^{\text{true}} + \Delta t \alpha (\Delta T_{t-1}^{\text{true}})^{\beta} + \epsilon \quad (16)$$

其中: Δt 为时间步长; ϵ 为轴承退化过程中的不确定度。

1.2.3 基于PF算法的RUL预测

采用基于抽样的PF算法估计轴承温差变化状态,并完成评估值的更新^[22]。根据动态演化模型中更新产生的模型参数 $\boldsymbol{\theta}_t = (\alpha_t, \beta_t)$ 与时刻 t 之前的轴承观测数据 $\Delta T_{1:t}^{\text{obs}}$,得到轴承温差变化状态的后验分布 $p(\Delta T_t^{\text{true}}|\Delta T_{1:t}^{\text{obs}}, \boldsymbol{\theta})$,其计算公式为

$$p(\Delta T_t^{\text{true}}|\Delta T_{1:t}^{\text{obs}}, \boldsymbol{\theta}) = \sum_{j=1}^{N_s} \tilde{w}_t^{(j)} \delta(\Delta T_t^{\text{true}} - \Delta T_t^{(j)}) \quad (17)$$

其中: N_s 为粒子个数; $w_t^{(j)}$ 为 t 时刻第 j 个粒子对应的权重; $\delta(\cdot)$ 为狄拉克函数; $\Delta T_t^{(j)}$ 为 t 时刻产生的第 j 个粒子。

权重 $\tilde{w}_t^{(j)}$ 的更新公式为

$$\tilde{w}_t^{(j)} = \frac{w_t^{(j)}}{\sum_{j=1}^{N_s} w_t^{(j)}} \quad (18)$$

其中: $w_t^{(j)} = w_{t-1}^{(j)} p(\Delta T_t^{\text{obs}}|\Delta T_t^{(j)})$ 。

通过随机重采样策略实现重置各粒子的权重^[23],得到轴承温差变化状态的后验分布表达式为

$$p(\Delta T_t^{\text{true}}|\Delta T_{1:t}^{\text{obs}}, \boldsymbol{\theta}) = \frac{1}{N_s} \sum_{j=1}^{N_s} \delta(\Delta T_t^{\text{true}} - \Delta T_t^{(j, \text{res})}) \quad (19)$$

其中: $\Delta T_t^{(j, \text{res})}$ 为重采样后第 j 个粒子的温差值。

基于 t 时刻之前的轴承观测数据 $\Delta T_{1:t}^{\text{obs}}$ 和 t 时刻的模型参数 $\boldsymbol{\theta}_t = (\alpha_t, \beta_t)$,预测轴承 $t+k$ 时刻的温差变化状态 $p(\Delta \bar{T}_{t+k}|\Delta T_t', \boldsymbol{\theta}_t)$,计算式为

$$p(\Delta T_{t+k}^{\text{true}}|\Delta T_{1:t}^{\text{obs}}, \boldsymbol{\theta}) = \frac{1}{N_s} \sum_{j=1}^{N_s} \delta(\Delta T_{t+k}^{\text{true}} - \Delta T_{t+k}^{(j)}) \quad (20)$$

轴承的RUL可定义为在当前退化状态和对应的模型参数下,预测轴承未来状态首次达到失效阈值和当前时刻的时间间隔,即基于退化模型和动态演化模型延拓轴承的退化曲线达到预先设定的失效阈值,从而实现轴承RUL预测。

$$\text{RUL}_t^{(j)} = \inf\{k > 0 | \Delta T_{t+k}^{(j)} \geq \Delta T_{\text{th}}\} \quad (21)$$

其中: $\text{RUL}_t^{(j)}$ 为 t 时刻第 j 个粒子的剩余寿命预测值; k 为时间步,每次迭代 $k = k + 1$; ΔT_{th} 为失效阈值。

根据轴承粒子温差估计值与观测值之间的差值,计算RUL粒子空间权重。

归一化后权重 $\tilde{w}_{\text{RUL},t}^{(j)}$ 的计算式为

$$\tilde{w}_{\text{RUL},t}^{(j)} = \frac{w_{\text{RUL},t}^{(j)}}{\sum_{j=1}^{N_s} w_{\text{RUL},t}^{(j)}} \quad (22)$$

t 时刻第 j 个RUL粒子的权重 $w_{\text{RUL},t}^{(j)}$ 的计算式为

$$w_{\text{RUL},t}^{(j)} = w_{\text{RUL},t-1}^{(j)} p(\Delta T_t^{\text{obs}}|\Delta T_t^{(j)}) \quad (23)$$

结合权重对RUL粒子空间中的粒子进行更新,得到当前时刻的剩余寿命估计值,其计算式为

$$\widehat{\text{RUL}}_t = \sum_{j=1}^{N_s} \tilde{w}_{\text{RUL},t}^{(j)} \cdot \text{RUL}_t^{(j)} \quad (24)$$

其中: $\widehat{\text{RUL}}_t$ 为第 t 时间步对应的RUL预测值。

轴承退化过程易受随机因素影响,为了表征预测结果的差异程度,采用平均相对误差(mean relative accuracy,简称MRA)对剩余寿命预测方法的性能进行评估。MAR值越大,则预测的精度越高。平均相对误差的计算公式为

$$\text{MRA} = \frac{1}{n} \sum_{i=1}^n \text{RA}_i \quad (25)$$

其中: $\text{RA}_i = 1 - \frac{|\widehat{\text{RUL}}_i - \text{RUL}_i^{\text{true}}|}{\widehat{\text{RUL}}_i}$; $\text{RUL}_i^{\text{true}}$ 为在第 i

个时间步长对应的剩余寿命实际值; n 为参与评估的时间步长总数。

2 实施步骤

非稳态工况下数模联合驱动的轴承剩余寿命预测方法流程如图5所示,具体步骤如下:

- 1) 对轴承全寿命周期温度信号进行数据筛选,获取正常工况数据,并进行数据清洗与插值处理;
- 2) 对数据进行初次重采样,基于历史数据拟合温差变化模型参数,结合转速信息提取轴承退化特征;
- 3) 再次进行数据重采样,并基于时变 3σ 准则确定轴承退化起始点,提取退化数据;
- 4) 利用退化数据的前半部分获取初始模型参数;




图5 轴承剩余寿命预测方法流程图

Fig.5 Flowchart of the bearing remaining useful life prediction method

- 5) 在时间步长为 t 时基于观测值 ΔT_i^{obs} , 通过式(15)更新模型参数的后验分布 $p(\Theta_i, \Delta T_{1:t}^{\text{obs}})$;
- 6) 使用更新后的模型参数 $\Theta_i = (\alpha_i, \beta_i)$ 和退化指标, 根据式(17)~(20)计算轴承性能退化状态的后验分布;
- 7) 在后验状态评估的基础上, 根据式(20)预测轴承在未来时刻的退化状态 $p(\Delta T_i^{\text{true}} | \Delta T_{1:t}^{\text{obs}}, \Theta_i)$, 并对退化轨迹延拓至失效阈值 ΔT_{th} ;
- 8) 令 $i = i + 1$, 重复步骤 5~8, 直至 ΔT_i^{obs} 到达失效阈值;
- 9) 基于上一时间步预测的温差值和观测值之间的插值来优化 RUL 粒子的权重, 根据式(24)计算轴承的剩余寿命。

3 实例验证

3.1 实例说明

为验证所提出方法的有效性, 以工程某设备为例进行验证。数据在变工况条件下采集, 轴承编号分别为 B-1、B-2、B-3、B-4 和 B-5。其中: B-1、B-2 和 B-3 为故障轴承数据; B-4 和 B-5 为正常轴承数据。表 1 为轴承数据信息。

图 6 为重采样效果对比图。通过初次重采样, 有效减少了信号正常段的波动, 消除了机械设备在运行过程中因加润滑剂等操作导致的轴承温差值异常下降, 有效保留了信号中的冲击成分。

表 1 轴承数据信息

Tab.1 Bearing data information

轴承编号	采样时间	轴承状态	数据量
B-1	2021.01.01~2024.06.11	故障	8 980 232
B-2	2021.01.01~2024.06.20	故障	10 180 629
B-3	2021.01.27~2023.01.24	故障	7 736 164
B-4	2021.01.17~2023.01.11	正常	8 768 694
B-5	2021.01.14~2023.01.11	正常	8 654 177




图6 重采样效果对比图

Fig.6 Comparison of resampling effects

3.2 退化特征提取分析

基于温差模型, 去除实时监测信号序列中的温差转速分量, 提取轴承监测数据中的退化特征。图 7 为去除转速分量后的温差对比。可以看到: 去除转速分量后, 正常状态下轴承温差值在 0 °C 附近波动; 故障发生后, 随着轴承的持续运行, 温差值逐渐增大, 能够有效甄别轴承的运行状态。




图7 去除转速分量后的温差对比

Fig.7 Comparison of temperature difference after removing rotational speed component

3.3 早期退化监测分析

轴承在正常状态下,其 ΔT_i 在一定区间内波动,会增加后续监测中的误报情况。因此,再次使用重采样以减少正常状态下温差信号的波动程度。图8为轴承重采样效果对比图。




图8 轴承重采样效果对比图

Fig.8 Comparison of bearing resampling effects

轴承在正常状态下处于同一数据分布,降低了随机波动带来的干扰。结合时变 3σ 准则确定退化起始点。图9为轴承监测报警结果。可以看出,该方法能够有效区分正常数据和故障数据,相较于传统的阈值判别和 3σ 准则,减少了对先验数据的需求,并降低了因局部冲击引起的误报。




图9 轴承监测报警结果

Fig.9 Bearing monitoring and alarm results

3.4 剩余寿命预测结果分析

为满足工程实际对轴承寿命预测的要求,将数据按天进行聚合,取数据的平均值作为有效值。笔

者仅对轴承失效前两个月的数据进行预测,以失效前第3、4个月的数据作为初始模型参数,采用基于最小二乘法的回归方法直接获取模型参数。

轴承模型参数更新过程如图10所示。图中:红线为该时间步长下模型参数的均值;概率密度为量纲一的量。可以看出:①随着实时监测数据的不断修正,模型参数逐渐向理论值聚集;②参数变化幅度较小,说明基于轴承自身退化趋势获取模型参数更为合理。




图10 轴承模型参数更新过程

Fig.10 Updating process of bearing model parameters

图11为轴承粒子概率密度变化图。其中:红色虚线为轴承的实际剩余寿命;概率密度为量纲一的量。可以看到,粒子的聚集区域围绕在实际曲线的周围。




图11 轴承粒子概率密度变化图

Fig.11 Variation of particle probability density for bearing

根据温差信号预测值与观测值的差值更新粒子权重,得到粒子权重矩阵,进而得到轴承剩余寿命预测值。B-1、B-2和B-3的寿命预测结果对比分别如图12~14所示。




图12 B-1寿命预测结果对比

Fig.12 Comparison of RUL prediction results for B-1




图13 B-2寿命预测结果对比

Fig.13 Comparison of RUL prediction results for B-2




图14 B-3寿命预测结果对比

Fig.14 Comparison of RUL prediction results for B-3

为进一步说明本研究方法的有效性,将其与部分模型驱动方法及数据驱动方法进行对比。模型驱动方法包括结合单指数模型、双指数模型和多项式模型的方法,模型参数均采用每次迭代加上一个正

态随机数的方法进行更新。数据驱动方法包括 BCCN1, BCNN2, 贝叶斯大核注意力网络 (Bayesian large-kernel attention network, 简称 BLKAN), Transformer 等机器学习方法。其中: BCNN1 和 BCNN2 为 CNN 的衍生网络。BCNN1 通过对网络权重进行贝叶斯推理, 获得较好的性能与不确定性评估。BCNN2 通过随机采样实现类似的效果。模型驱动方法基于笔者提取的退化特征数据进行更新预测; 而所采用的深度学习方法均基于原始数据进行训练与测试, 其退化特征提取过程通过网络自动完成, 仅进行了简单的数据清洗。结果表明, 本研究方法提取的退化特征优于深度网络方法, 且轴承剩余寿命预测结果更为平稳、准确。

通过计算 MRA 值来评价各方法的实际性能, 提出方法与其他方法的 MRA 值对比如表 2 所示。可以看出, 提出方法在 90% 置信区间内的预测精度均在 85% 以上, 在与其他方法的对比中均取得最优结果。

表 2 提出方法与其他方法的 MRA 值对比
Fig.2 Comparison of MRA values between the proposed method and other methods %

方法	轴承编号		
	B-1	B-2	B-3
单指数	89.51	50.41	66.81
双指数	87.31	57.31	45.81
多项式	80.31	61.68	76.91
BCNN1	26.08	70.87	61.34
BCNN2	29.91	66.30	32.98
BLKAN	46.74	70.18	35.69
Transformer	-0.01	58.20	-22.24
提出方法	95.32	95.48	87.52

4 结 论

- 1) 构建了考虑转速连续变化的轴承温差变化模型, 结合转速信号与历史正常温差数据, 拟合得到各轴承的模型参数。该模型可剔除转速干扰, 提取的故障特征能够从幅值维度有效区分轴承的正常与故障状态。
- 2) 时变 3σ 准则能够基于实时监测数据动态调整阈值, 依赖较少先验信息即可满足设备实时监测需求。为避免端点异常值的影响, 取前 10 d 数据计算静态阈值, 再结合时变 3σ 准则进行动态监测, 实现了对故障轴承的有效报警。
- 3) 通过设计马尔可夫链近似求解模型参数的

先验分布, 实现了退化模型参数的动态更新。针对基于 PF 算法产生的 RUL 粒子, 利用轴承温差状态估计值与上一时刻观测值的差值更新粒子权重。经实际工程数据验证, 该方法的预测精度均达 85% 以上, 且所有结果均处于 90% 置信区间内, 为非稳态工况下轴承剩余寿命预测提供了有效参考。

参 考 文 献

[1] REZAMAND M, KORDESTANI M, CARRIVEAU R, et al. An integrated feature-based failure prognosis method for wind turbine bearings[J]. IEEE-ASME Transactions on Mechatronics, 2020, 25 (3) : 1468-1478.

[2] LIU Z H, MENG X D, WEI H L, et al. A regularized LSTM method for predicting remaining useful life of rolling bearings[J]. International Journal of Automation and Computing, 2021, 18(4): 581-593.

[3] LI X L, TENG W, PENG D K, et al. Feature fusion model based health indicator construction and self-constraint state-space estimator for remaining useful life prediction of bearings in wind turbines[J]. Reliability Engineering & System Safety, 2023, 233: 109124.

[4] HU A J, ZHU Y C, LIU S X, et al. A novel vision transformer network for rolling bearing remaining useful life prediction[J]. Measurement Science and Technology, 2024, 35(2): 025106.

[5] SHENG Y Y, LIU H Y, LI J B. Bearing performance degradation assessment and remaining useful life prediction based on data-driven and physical model[J]. Measurement Science and Technology, 2023, 34(5) : 055002.

[6] JIANG G J, YANG J S, CHENG T C, et al. Remaining useful life prediction of rolling bearings based on Bayesian neural network and uncertainty quantification[J]. Quality and Reliability Engineering International, 2023, 39(5): 1756-1774.

[7] PEETERS C, GUILLAUME P, HELSEN J. Vibration-based bearing fault detection for operations and maintenance cost reduction in wind energy[J]. Renewable Energy, 2018, 116: 74-87.

[8] WANG L, CAO H R, YE Z S, et al. DVGTformer: a dual-view graph transformer to fuse multi-sensor signals for remaining useful life prediction[J]. Mechanical Systems and Signal Processing, 2024, 207: 110935.

[9] 王前, 黄强, 江星星, 等. 基于融合特征与数模联动的轴承寿命预测方法[J]. 振动、测试与诊断, 2023, 43(4): 705-711.

WANG Qian, HUANG Qiang, JIANG Xingxing, et

- al. Bearing life prediction method based on fusion features and data-model linkage[J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(4): 705-711. (in Chinese)
- [10] 梁天添, 刘健, 梁贺焱, 等. 轴承剩余使用寿命预测的 IDSA-LSTMNN[J]. 振动、测试与诊断, 2025, 45(2): 273-280.
- LIANG Tiantian, LIU Jian, LIANG Heyan, et al. Remaining useful life prediction of bearings based on IDSA-LSTMNN[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(2): 273-280. (in Chinese)
- [11] ZHU J, CHEN N, SHEN C Q. A new data-driven transferable remaining useful life prediction approach for bearing under different working conditions[J]. Mechanical Systems and Signal Processing, 2020, 139: 106602.
- [12] LI J X, WANG Z H, SHEN L J. A novel RUL prediction method for rolling bearings based on dynamic control chart and adaptive incremental filtering[J]. Measurement Science and Technology, 2024, 35(10): 106138.
- [13] LU X C, YAO X J, JIANG Q S, et al. Remaining useful life prediction model of cross-domain rolling bearing via dynamic hybrid domain adaptation and attention contrastive learning[J]. Computers in Industry, 2025, 164: 104172.
- [14] CERRADA M, SÁNCHEZ R V, LI C, et al. A review on data-driven fault severity assessment in rolling bearings[J]. Mechanical Systems and Signal Processing, 2018, 99: 169-196.
- [15] REN X Y, QIN Y, LI B, et al. A core space gradient projection-based continual learning framework for remaining useful life prediction of machinery under variable operating conditions[J]. Reliability Engineering & System Safety, 2024, 252: 110428.
- [16] GAO Y Y, WEN Y X, WU J G. A neural Network-Based joint prognostic model for data fusion and remaining useful life prediction[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 117-127.
- [17] CAO H J, XIAO W, SUN J, et al. A hybrid data- and model-driven learning framework for remaining useful life prognostics[J]. Engineering Applications of Artificial Intelligence, 2024, 135: 108557.
- [18] LI J, LEI X, LI H, et al. Normal behavior models for the condition assessment of wind turbine generator systems[J]. Electric Power Components and Systems, 2014, 42(11): 1201-1212.
- [19] HU Y G, LI H, SHI P P, et al. A prediction method for the real-time remaining useful life of wind turbine bearings based on the Wiener process[J]. Renewable Energy, 2018, 127: 452-460.
- [20] WANG L, CAO H R, FU Y. A bearing prognosis framework based on deep wavelet extreme learning machine and particle filtering[J]. Applied Soft Computing, 2022, 131: 109763.
- [21] WANG P, LONG Z Q, WANG G. A hybrid prognostics approach for estimating remaining useful life of wind turbine bearings[J]. Energy Reports, 2020, 6(S9): 173-182.
- [22] TENG W, HAN C, HU Y, et al. A robust model-based approach for bearing remaining useful life prognosis in wind turbines[J]. IEEE Access, 2020, 8: 47133-47143.
- [23] CHENG F Z, QU L Y, QIAO W, et al. Enhanced particle filtering for bearing remaining useful life prediction of wind turbine drivetrain gearboxes[J]. IEEE Transactions on Industrial Electronics, 2019, 66(6): 4738-4748.



第一作者简介:熊亮,男,2000年4月生,硕士。主要研究方向为轴承剩余寿命预测。

E-mail: xlsy05030828@163.com

通信作者简介:曹宏瑞,男,1982年12月生,博士、教授、博士生导师。主要研究方向为航空发动机数字孪生建模、故障机理分析、故障诊断与预测。

E-mail: chr@mail.xjtu.edu.cn