DOI: 10.3901/JME.2021.20.029

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*

李乃鹏 蔡 潇 雷亚国 徐鹏程 王文廷 王 彪

(西安交通大学现代设计及转子轴承系统教育部重点实验室 西安 710049)

摘要: 随着传感和信息技术的发展, 各式各样的传感器获取了机械装备海量的监测数据, 让剩余寿命预测有“据”可依, 推动机械剩余寿命预测进入了大数据时代。但由于数据类型多样、量大面广, 如何利用丰富的多传感器数据, 从中快速挖掘健康状态退化信息, 指导寿命预测, 成为大数据时代下机械寿命预测的全新挑战。基于模型的寿命预测方法大多仅针对单一监测数据进行建模分析, 无法有效利用丰富的大数据资源。数据驱动的方法则过分依赖训练数据, 缺乏必要的经验指引, 方法的可解释性差。为了有效利用多传感器数据指导寿命预测, 从数模联动的思路出发, 建立了一种融合多传感器数据的数模联动寿命预测方法。采用一种通用的 Wiener 过程模型对健康状态退化过程进行描述, 分别建立多源观测函数和多源映射函数对状态与数据之间的因果关系和关联关系进行描述, 采用粒子滤波算法将多传感器数据与模型进行动态匹配, 预测剩余寿命。在提出方法的统一框架指导下, 选取三种特定模型对铣刀剩余寿命进行预测, 验证了提出方法的有效性。

关键词: 机械装备; 剩余寿命预测; 大数据; 数模联动; 多传感器融合

中图分类号: TH17

A Model-data-fusion Remaining Useful Life Prediction Method with Multi-sensor Fusion for Machinery

LI Naipeng CAI Xiao LEI Yaguo XU Pengcheng WANG Wenting WANG Biao

(Key Laboratory of Education Ministry for Modern Design and Rotor-Bearing System,
Xi'an Jiaotong University, Xi'an 710049)

Abstract: With the development of sensing and information technology, massive data have been collected from machinery by various sensors for remaining useful life (RUL) prediction, which has promoted mechanical RUL prediction entering the big data era. Meanwhile, it is still a big challenge to quickly mine degradation information from massive multi-sensor data to guide RUL prediction. Most model-based methods only focus on a one-dimensional degradation data, thus cannot effectively utilize the rich data resources. Data-driven methods are highly dependent on monitoring data. They do not rely on any experimental knowledge. Thus, they suffer from the problem of poor interpretability. To fuse multi-sensor signals for RUL prediction, a model-data-fusion RUL prediction method with multi-sensor fusion is established based on the basic idea of model and data fusion. In this method, the degradation process is expressed by a generalized Wiener process model. The relationship between states and data are interpreted from the aspects of causality and correlation using multivariate measurement function and multivariate mapping function. Multi-sensor data are fused to update the model in real time using the particle filtering algorithm for RUL prediction. Under the basic framework of the proposed method, three specific models are selected to predict the RUL of milling cutters. The prediction results verify the effectiveness of the proposed method.

Key words: machinery; remaining useful life prediction; big data; model-data-fusion; multi-sensor fusion

* 国家自然科学基金(52005387, 52025056)、NSFC-浙江两化融合联合基金(U1709208)和中国博士后科学基金(2020M673380)资助项目。20201111 收到初稿, 20210806 收到修改稿

0 前言

机械装备在长期服役过程中由于疲劳磨损、环境腐蚀等,不可避免地会产生性能和健康状态的退化,导致最终失效。传统的以可靠性理论为基础的定期维护策略,通过对大量同批次产品失效时间的统计分析,得到失效时间分布^[1],从而设定特定时间间隔进行停机检修。然而,由于机械装备服役环境复杂多变,不同个体之间差异显著,由大量失效装备统计得到的失效时间与实际服役装备的失效时间相差甚远,无法有效指导维修工作的顺利实施^[2]。为了满足机械装备的安全性和经济性需求,基于状态监测的预测性维护应运而生。该策略通过在机械装备上加装振动、温度、电流等传感器,实时获取装备监测数据,掌握装备的健康状态退化趋势,再基于一定的工程经验和失效判据,对其剩余寿命进行预测,从而在装备失效前制定最佳维修计划,避免重大事故发生,实现经济效益的最大化^[3]。

近年来,随着信息和传感技术的高速发展,机械装备健康监测变得越来越信息化、网络化、智能化。各式传感器和数据传输系统犹如一张庞大的神经网络遍布在机械系统内部,源源不断地获取监测数据,实时感知装备的一举一动,推动着机械剩余寿命预测进入大数据时代。例如,英国罗-罗公司实时监控着全世界数以万计的飞机引擎,每部引擎约有 100 个传感器,采集着引擎的压力、温度、速度等信号,每年传送着 PB 级的数据^[4]。美国 GE 公司能源监测平台监测着 60 个国家 1 500 多台燃气轮机,单台服务器能同时连接 3 000 多个采集器,数据总量达 50 TB^[5]。中国华电集团的风电远程诊断平台监测着全国 7 200 多台风机,监测信号包含转速、振动、温度等多种类型,平台单月数据累积量高达 14 TB。监测大数据为寿命预测提供了丰富的健康状态退化信息,然而由于传感器种类杂、测点多,不同传感器对状态退化的敏感度不同,测点之间既存在差异又相互关联,如何充分利用不同种类、不同测点的监测数据,有效融合多传感器数据的状态退化信息,实现对机械装备剩余寿命的准确预测,已成为大数据时代下机械剩余寿命预测的关键。

现有的剩余寿命预测方法根据其原理可大体分为两大类:基于模型的方法和数据驱动的方法^[6]。基于模型的方法通常根据装备退化机理或监测数据的退化趋势建立物理模型或经验模型,将装备退化行为用特定的数学函数表达式进行描述。常见的物

理模型如用于失效分析的 S-N 疲劳寿命曲线^[7]和 Paris-Erdogan 模型^[8]等。由于物理模型中内部应力、材料力学参数等很难在线获取,因此目前学者们常将物理模型改良为一种经验模型,对模型参数的物理意义进行模糊化处理,基于监测数据进行参数在线估计^[9]。常用的经验模型有随机参数模型^[10]、Gamma 过程模型^[11]、Wiener 过程模型^[12]等。物理模型常将退化速率描述为关于状态的函数,经验模型则常将退化速率描述为关于时间的函数。为了将两者统一,文献[13]中提出了一种关于时间和状态的通用 Wiener 过程模型。由于基于模型的方法以退化机理或经验知识作为指引,在监测数据退化趋势明显的情况下能够提供准确可靠的预测结果。但该类方法通常仅对单一监测数据进行建模分析,无法充分利用多传感器监测数据所蕴含的丰富状态退化信息。

数据驱动的方法无需对装备退化机理和规律进行深入分析,通过借助一些机器学习算法,如支持向量机(Support vector machine, SVM)^[14]、相关向量机(Relevance vector machine, RVM)^[15]、人工神经网络(Artificial neural network, ANN)^[16]、神经模糊推理系统(Adaptive network-based fuzzy inference system, ANFIS)^[17]等,从监测数据中提取健康指标,建立健康指标与剩余寿命间的非线性映射关系^[18]。近几年,随着深度学习理论不断发展,一些深度学习模型也逐渐被引入到机械剩余寿命预测中^[19],例如卷积神经网络(Convolutional neural network, CNN)^[20]、递归神经网络(Recursive neural network, RNN)^[21]、长短时记忆网络(Long short-term memory, LSTM)^[22]等。随着深度学习模型的数据挖掘能力不断增强,该类方法逐渐摒弃对专家知识的依赖,直接从原始数据中自主学习装备退化规律,实现原始数据到剩余寿命的映射^[23-24]。然而,数据驱动的方法需要大量失效装备的全寿命数据进行模型训练,过分依赖训练数据,在处理多传感器融合预测问题时,无法对健康状态退化行为与不同传感器数据之间的关系进行明确解释。

针对现有剩余寿命预测方法在处理多传感器融合预测中所存在的问题,基于经验模型和贝叶斯更新算法,建立了一种多传感器融合数模联动寿命预测方法,通过构建多源状态空间模型对健康状态与多传感器数据之间的关系进行明确解释,采用多传感器数据对模型进行联合动态更新,融合多传感器数据预测剩余寿命。机械状态退化过程采用通用 Wiener 过程模型^[13]进行描述。状态与监测数据之间的关系则从两种不同视角进行解释:① 将系统状态作为内因,多传感器数据视为系统状态的外部响应,

建立“一对多”的多源观测函数，对两者间的因果关系进行描述；② 从数据间的关联关系出发，建立“多对一”的多源映射函数，揭示多传感器数据与状态之间的映射关系。为确保方法的通用性，模型中的函数关系均采用一般通式进行描述，并将多种类型的退化模型和机器学习算法整合在了统一方法框架下。同时提出一种敏感度排序测点选择算法选取敏感测点，并采用粒子滤波算法融合敏感测点数据进行状态在线评估和寿命预测。以铣床刀具磨损试验数据为例，在统一方法框架下，选取三种特定模型预测刀具剩余寿命，验证了方法的通用性和有效性。

1 通用 Wiener 过程退化模型

机械装备由于受到载荷随机波动、内部材质不均、运行工况时变等多源随机因素的影响，其状态退化过程表现出明显的不确定性。Wiener 过程退化模型是一种描述随机退化过程的常用模型，在机械剩余寿命预测中被广泛应用^[12, 25]。本文采用一种关于时间和状态的通用 Wiener 过程模型对机械状态退化过程进行描述^[13]。

$$x(t) = x(0) + \int_0^t \mu(x(\tau), \tau) d\tau + \int_0^t \sigma(\tau) dB(\tau) \quad (1)$$

式中， $x(t)$ 为 t 时刻的状态， $\mu(x(\tau), \tau)$ 为描述瞬时退化速率的函数， τ 为积分项中时间的变体， $\sigma(\tau)$ 为描述随机波动方差大小的时变函数， $B(\tau)$ 为标准布朗运动。

将剩余寿命定义为状态值首次达到失效阈值所对应的剩余时长

$$L = \inf \{l : x(l + t_k) \geq D | x_k < D\} \quad (2)$$

式中， L 为 t_k 时刻的剩余寿命， $\inf\{\cdot\}$ 为下限函数， l 为 t_k 时刻之后的运行时间变量， D 为失效阈值， x_k 为 t_k 时刻的状态值。

根据文献[13, 26]中的推导结果，剩余寿命的概率密度函数可用下式近似表示

$$f(l|x_k) \cong \left[\frac{D - x_k - \int_0^l \mu(x(\tau + t_k), \tau + t_k) d\tau}{\int_0^l \sigma^2(\tau + t_k) d\tau} + \frac{\mu(x(l + t_k), l + t_k)}{\sigma^2(l + t_k)} \right] \frac{\sigma^2(l + t_k)}{\sqrt{2\pi \int_0^l \sigma^2(\tau + t_k) d\tau}} \times \exp \left(-\frac{\left(D - x_k - \int_0^l \mu(x(\tau + t_k), \tau + t_k) d\tau \right)^2}{2 \int_0^l \sigma^2(\tau + t_k) d\tau} \right) \quad (3)$$

由于式(3)积分项中包含未来状态退化轨迹 $\{x(\tau + t_k)\}_{0 \leq \tau \leq l}$ ，而实际中未来退化轨迹是未知量。

因此式(3)只提供了剩余寿命概率分布的理论计算结果，无法直接应用。为了得到剩余寿命概率分布的数值估计结果，文献[13]提出了一种随机退化轨迹模拟寿命概率估计算法。该算法的基本思路如下。

(1) 已知当前时刻状态值为 x_k ，产生一组初始状态粒子 $\{x_n(t_k) = x_k\}_{n=1:N_s}$ ，其中 N_s 为粒子个数。

(2) 根据状态退化模型采用以下状态传递函数对初始粒子进行迭代递推

$$x_n(l_i + t_k) = x_n(l_{i-1} + t_k) + \mu(x_n(l_{i-1} + t_k), l_{i-1} + t_k) \Delta l_{i-1} + \omega_{i-1} \quad (4)$$

式中， $x_n(l_i + t_k)$ 为第 n 个粒子在 $l_i + t_k$ 时刻的状态值， $\Delta l_{i-1} = l_i - l_{i-1}$ 为第 i 步迭代的时间间隔，为保证粒子失效时间点的多样性，迭代时间间隔会根据迭代过程中产生的失效粒子个数自适应调整， ω_{i-1} 为状态传递噪声。

(3) 重复步骤(2)直到所有粒子都已超过失效阈值 D 。得到 N_s 组失效粒子的未来退化轨迹。

(4) 将 N_s 组退化轨迹代入式(3)得到每一条退化轨迹在对应失效点的剩余寿命概率密度值。

(5) 采用下式将所有粒子的剩余寿命估计值进行整合，得到剩余寿命概率分布的估计结果。

$$f(l|x_k) \cong \frac{\sum_{n=1}^{N_s} p_n(l = l_{L_n}) \delta(l - l_{L_n})}{\sum_{n=1}^{N_s} \delta(l - l_{L_n})} \quad (5)$$

式中， L_n 为第 n 个粒子从 x_k 到首次超过 D 的迭代步数， l_{L_n} 为其剩余寿命， $p_n(l = l_{L_n})$ 为将第 n 个粒子的退化轨迹代入式(3)得到的剩余寿命概率值， $\delta(\cdot)$ 为狄拉克函数。

2 多传感器融合数模联动寿命预测

提出的多传感器融合数模联动寿命预测方法流程如图 1 所示。首先，从模型库中选取合适的函数进行模型构建；然后，利用数据库中失效样本数据对模型进行离线训练和敏感测点选择；其次，利用监测样本的实时观测数据对模型进行在线更新；最后，基于更新的模型预测装备剩余寿命。各环节详细步骤如下。

2.1 模型构建

构建多源状态空间模型对以下两种行为关系进

行描述:① 构建状态传递函数对机械装备真实健康状态物理退化过程进行描述,例如轴承剥落面积的扩展、齿轮疲劳裂纹的生长、刀具磨损厚度的增长等;② 构建多源观测函数或多源映射函数对健康状态与多传感器数据之间的关系进行描述。

2.1.1 状态退化过程建模

基于式(1)构建如下状态传递函数

$$x_k = x_{k-1} + \mu(x_{k-1}, t_k, \theta) \Delta t_{k-1} + \omega_{k-1} \quad (6)$$

式中, $\mu(x_{k-1}, t_k, \theta)$ 为退化速率, θ 表示其未知参数, $\Delta t_{k-1} = t_k - t_{k-1}$ 为前后两时刻的间隔。图1中列举了几种常见的退化速率表达式: 常数 η , 关于时间的 at_k^b 、 $a \exp(bt_k)$, 关于状态的 ax_{k-1}^b 、 $a \exp(bx_{k-1})$, 其具体形式可根据失效样本数据采用赤池信息准则(Akaike information criterion, AIC)、贝叶斯信息准则(Bayesian information criterion, BIC)等评价准则进行选择。 $\omega_{k-1} \sim N(0, \sigma^2(t_{k-1}, \epsilon) \Delta t_{k-1})$ 为状态传递误差, ϵ 为其未知参数。

图1 多传感器融合数模联动寿命预测方法流程

2.1.2 状态与多传感器数据之间关系建模

分别从因果关系和关联关系两种不同的视角对状态序列与多传感器数据之间的关系进行解释:① 将系统状态作为内因,多传感器数据视为系统状态的外部响应,建立“一对多”的多源观测函数,对两者间的因果关系进行描述;② 从数据间的关联关系出发,建立“多对一”的多源映射函数,揭示多传感器数据与状态之间的映射关系。

(1) 多源观测函数。首先考虑单个传感器数据与状态之间的函数关系。将观测数据描述为关于状态的一维观测函数

$$y_k^p = a_p \varphi(x_k, \theta_p) + b_p + v_k^p \quad (7)$$

式中, y_k^p 为第 p 个测点在 t_k 时刻的观测值, $\varphi(x_k, \theta_p)$ 为描述观测数据随状态变化的函数关系式, θ_p 表示其未知参数,图1中列举了几种常见函

数关系： x_k 、 x_k^c 、 $\exp(cx_k)$ 、 $\ln(cx_k)$ ，其具体形式同样可采用 AIC、BIC 等模型评估准则确定。 a_p 和 b_p 分别为斜率因子和截距因子， $v_k^p \sim N(0, \sigma_p^2)$ 为观测误差。

再考虑多个传感器数据之间的相关性。由于不同传感器数据为同一状态退化过程的系统响应，受到相同外部环境的干扰，因此其观测误差之间存在一定的相关性。假设共有 P 组传感器数据，将其观测函数进行融合，构造以下多源观测函数

$$\begin{pmatrix} y_k^1 \\ y_k^2 \\ \vdots \\ y_k^P \end{pmatrix} = \begin{pmatrix} a_1 & 0 & \cdots & 0 \\ 0 & a_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & a_P \end{pmatrix} \begin{pmatrix} \varphi(x_k, \mathbf{g}_1) \\ \varphi(x_k, \mathbf{g}_2) \\ \vdots \\ \varphi(x_k, \mathbf{g}_P) \end{pmatrix} + \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_P \end{pmatrix} + \begin{pmatrix} v_k^1 \\ v_k^2 \\ \vdots \\ v_k^P \end{pmatrix} \quad (8)$$

式中，观测误差 $(v_k^1, v_k^2, \dots, v_k^P)^T$ 服从多变量正态分布 $N(0, \Sigma)$ ，其中

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{1,2} & \cdots & \sigma_{1,P} \\ \sigma_{1,2} & \sigma_2^2 & \cdots & \sigma_{2,P} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1,P} & \sigma_{2,P} & \cdots & \sigma_P^2 \end{pmatrix} \quad (9)$$

式中， $\sigma_{i,j} (i \neq j)$ 为第 i 和第 j 个测点观测误差的协方差。

(2) 多源映射函数。与多源观测函数不同，多源映射函数从数据之间的关联性出发，通过数据驱动的方法建立多源观测数据与状态序列之间的映射关系，其函数关系可用如下通式表示

$$x_k = g(\mathbf{Y}_k) + \varepsilon_k \quad (10)$$

式中， $\mathbf{Y}_k = (y_k^1, y_k^2, \dots, y_k^P)^T$ 为多测点数据组成的集合， $g(\cdot)$ 表示从多维观测数据 $\mathbf{Y}_k$ 到一维状态数据 x_k 之间的映射函数， ε_k 为状态拟合误差。图 1 中给出了几种映射函数。例如回归分析中常用的线性回归模型： $a_0 + \sum_{p=1}^P a_p y_k^p + \varepsilon_k$ ；寿命预测中常用的机器学习模型：SVM、ANFIS、ANN 等。ANN 模型又包括常用的浅层网络，如前向反馈网络(Back propagation neural network, BPNN)、高斯径向基函数网络(Radial basis function network, RBF)等；以及深层网络，如 CNN、RNN、LSTM 等。此外，只要满足“多对一”非线性映射关系的机器学习模型都可用于构造多源映射函数。

2.1.3 多源状态空间模型

将状态传递函数与多源观测函数或多源映射函

数相结合，最终形成图 1 中所示的两类多源状态空间模型。实际应用中可根据不同类型函数对观测数据与状态数据之间关系的拟合能力选择最优的模型结构和函数类型。

2.2 离线训练

离线训练环节需要根据，失效样本观测数据估计模型的未知参数。假设数据库中已经积累了 N 组失效样本的数据，其中样本 n 的状态观测序列为 $(x_{n,1}, x_{n,2}, \dots, x_{n,K_n})^T$ ， K_n 为样本 n 的观测点数。共有 P 个测点的观测数据，其中测点 P 在状态观测序列对应时刻的观测值为 $(y_{n,1}^P, y_{n,2}^P, \dots, y_{n,K_n}^P)^T$ 。

在状态传递函数中，未知参数包括参数向量 θ 和 ϵ 。由式(6)可知 $\Delta x_{n,k-1} = x_{n,k} - x_{n,k-1}$ 服从正态分布 $N(\mu(x_{n,k-1}, t_{n,k}, \theta) \Delta t_{n,k-1}, \sigma^2(t_{n,k-1}, \epsilon) \Delta t_{n,k-1})$ ，则参数集 θ 和 ϵ 的对数似然函数为

$$\begin{aligned} \ell(\theta, \epsilon | X) = & - \sum_{n=1}^N \frac{K_n - 1}{2} \ln(2\pi) - \\ & \sum_{n=1}^N \sum_{k=1}^{K_n-1} \left(\frac{1}{2} \ln(\sigma^2(t_{n,k-1}, \epsilon) \Delta t_{n,k-1}) + \right. \\ & \left. \frac{(\Delta x_{n,k-1} - \mu(x_{n,k-1}, t_{n,k}, \theta) \Delta t_{n,k-1})^2}{2\sigma^2(t_{n,k-1}, \epsilon) \Delta t_{n,k-1}} \right) \end{aligned} \quad (11)$$

通过求解使式(11)最大时 θ 和 ϵ 的取值，即可得到未知参数估计值。

在多源观测函数中，未知参数包括 $\mathbf{g}_p$ 、 a_p 、 b_p 和 Σ 。对于每组测点的参数 $\mathbf{g}_p$ 、 a_p 和 b_p ，可分别将该测点观测数据代入式(12)，采用最小二乘拟合估计得到

$$\min_{\mathbf{g}_p, a_p, b_p} \left(\sum_{n=1}^N \sum_{k=1}^{K_n} (y_{n,k}^p - a_p \varphi(x_{n,k}, \mathbf{g}_p) - b_p)^2 \right) \quad (12)$$

对于包含不同测点相关性信息的协方差矩阵 Σ ，根据式(8)可知，样本 n 在 $t_{n,k}$ 时刻由多个测点组成的数据集 $\mathbf{Y}_{n,k} = (y_{n,k}^1, y_{n,k}^2, \dots, y_{n,k}^P)^T$ 满足多变量正

态分布 $N(\mathbf{A}\Phi_{n,k} + \mathbf{B}, \Sigma)$ ，其中 $\mathbf{A} = \begin{pmatrix} a_1 & 0 & \cdots & 0 \\ 0 & a_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & a_P \end{pmatrix}$ ， $\Phi_{n,k} = \begin{pmatrix} \varphi(x_{n,k}, \mathbf{g}_1) \\ \varphi(x_{n,k}, \mathbf{g}_2) \\ \vdots \\ \varphi(x_{n,k}, \mathbf{g}_P) \end{pmatrix}$ ， $\mathbf{B} = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_P \end{pmatrix}$ 。协方差 Σ 的对数似

然函数为

$$\ell(\Sigma|Y) = \sum_{n=1}^N \left(-\frac{PK_n}{2} - \frac{K_n}{2} \ln|\Sigma| - \frac{\sum_{k=1}^{K_n} (Y_{n,k} - A\Phi_{n,k} - B)\Sigma^{-1}(Y_{n,k} - A\Phi_{n,k} - B)^T}{2} \right) \quad (13)$$

求解得到其极大似然估计值为

$$\hat{\Sigma} = \frac{\sum_{n=1}^N \sum_{k=1}^{K_n} (Y_{n,k} - A\Phi_{n,k} - B)(Y_{n,k} - A\Phi_{n,k} - B)^T}{\sum_{n=1}^N K_n} \quad (14)$$

在多源映射函数中, 对于线性回归模型可采用最小二乘法进行参数求解, 对于其他各类机器学习算法, 则可以将训练数据代入模型进行模型训练得到相应的参数。

2.3 测点选择

由于部分传感器数据对健康状态退化并不敏感, 不同传感器测点之间存在信息冗余, 因此提出一种敏感度排序测点选择算法, 在寿命预测之前从多传感器中选取最优测点组合, 以获得最准确的寿命预测结果。该算法的基本步骤如下。

(1) 将所有样本状态值整合到同一序列 $X = (x_{1,1}, \dots, x_{1,K_1}, x_{2,1}, \dots, x_{2,K_2}, \dots, x_{N,1}, \dots, x_{N,K_N})^T$ 中, 每个测点观测值按照相同顺序整合到同一序列 Y^p 中。计算每个测点序列与状态序列的敏感度

$$\rho_p = \frac{\left| \sum_{n=1}^N \left(\sum_{i=1}^{K_n} (\tilde{x}_{n,i} - \bar{x}) (\tilde{y}_{n,i}^p - \bar{y}^p) \right) \right|}{\sqrt{\sum_{n=1}^N \left(\sum_{i=1}^{K_n} (\tilde{x}_{n,i} - \bar{x})^2 \right) \sum_{n=1}^N \left(\sum_{i=1}^{K_n} (\tilde{y}_{n,i}^p - \bar{y}^p)^2 \right)}} \quad (15)$$

式中, $\tilde{x}_{n,i}$ 为 $x_{n,i}$ 在 X 升序排列中的序号, $\bar{x}$ 为所有状态序号的均值, $\tilde{y}_{n,i}^p$ 为 $y_{n,i}^p$ 在 Y^p 升序排列中的序号, $\bar{y}^p$ 为所有观测序号的均值。 $\rho_p \in [0,1]$, 其值越高说明该测点序列与状态序列的相关性越大, 即对健康状态退化越敏感。

(2) 计算所有测点敏感度, 将各测点按照敏感度由大到小排序, 选取排序靠前的 P 个测点构成测点组合 Ω_p , 依次产生 P 个测点组合。

(3) 分别将 P 个测点组合数据输入表 1 中的在线更新和寿命预测算法, 预测失效样本的剩余寿命。计算预测结果与真实寿命的加权相对误差 (Weighted relative error, WRE)

$$WRE_n = \frac{1}{K_n} \sum_{k=1}^{K_n} \frac{t_{n,k} |T_n - \hat{t}_{n,k} - t_{n,k}|}{T_n^2} \times 100\% \quad (16)$$

式中, T_n 为失效样本 n 的真实寿命, $\hat{t}_{n,k}$ 为样本 n 在

$t_{n,k}$ 时刻寿命预测结果的期望, WRE 值越低说明寿命预测误差越小。

计算每个测点组合预测得到的所有失效样本 WRE 的均值, 选择得分最小的测点组合作为最优敏感测点组合。

表 1 基于粒子滤波的在线更新与寿命预测算法

输入: 模型参数估计值, 状态初始值, 实时观测数据

• 在 t_0 时刻根据模型参数估计值和初始状态值, 随机采样产生一组参数粒子和状态粒子 $\{\theta_0^i, x_0^i\}_{i=1:N_s}$, 并赋予权值 $\{w_0^i = 1/N_s\}_{i=1:N_s}$ 。

• for $k = 1 : K_n$

• for $i = 1 : N_s$

• 采用以下状态递推公式对状态粒子进行迭代递推

$$x_k^i = x_{k-1}^i + \mu(x_{k-1}^i, t_k, \theta_{k-1}^i) \Delta t_{k-1} + \omega_{k-1}^i$$

• 在获得 t_k 时刻实测数据后, 进行参数与状态更新。

1) 对于多源观测函数, 将实测数据代入下式更新粒子权值

$$w_k^i = \frac{w_{k-1}^i}{\sqrt{(2\pi)^{|S|} |\Sigma_S|}} \exp \left(-\frac{(Y_{S,n,k} - A_S \Phi_{S,k} - B_S)^T \Sigma_S^{-1} (Y_{S,n,k} - A_S \Phi_{S,k} - B_S)}{2} \right)$$

式中, S 表示任意测点组合, $|S|$ 为组合中的测点个数, Σ_S 、 $Y_{S,n,k}$ 、 A_S 、 B_S 、 $\Phi_{S,k}$ 分别为各矩阵或向量对应的敏感测点元素组成的子矩阵或子向量。

2) 对于多源映射函数, 将实测数据代入训练好的模型中, 得到当前时刻状态评估值 $\hat{x}_k$, 然后代入下式更新粒子权值

$$w_k^i = \frac{w_{k-1}^i}{\sqrt{2\pi\sigma^2(t_k)}} \exp \left(-\frac{(x_k^i - \hat{x}_k)^2}{2\sigma^2(t_k)} \right)$$

• end for

• 归一化粒子权值, 采用模糊重采样算法^[26]对参数与状态粒子进行重采样, 得到一组新的粒子集 $\{\theta_k^i, x_k^i\}_{i=1:N_s}$, 将粒子权值重置为

$$\{w_k^i = 1/N_s\}_{i=1:N_s}。$$

• 取粒子中值 $\{\bar{\theta}_k, \bar{x}_k\}$ 作为评估结果, 代入 Wiener 过程模型, 预测得到当前时刻剩余寿命概率分布^[13]。

• end for

输出: 剩余寿命概率分布预测结果

2.4 在线更新与寿命预测

将选择出的最优敏感测点组合的实测数据输入到表 1 中的在线更新与寿命预测算法, 基于敏感测点数据对模型参数与状态进行在线更新, 并得到机械装备剩余寿命实时预测结果。

3 铣刀磨损试验验证

3.1 试验数据介绍

采用铣刀磨损试验数据对提出方法进行验证。本试验在 VMC850 型数控机床上进行, 试验台结构及测点布置如图 2 所示。试验台上共加装了五个不同类型传感器: 主轴上的三向加速度传感器, 工件下方的三向压力传感器, 主轴电机线圈上的电流钳, 工件附近的麦克风, 以及工件夹具上的声发射传感器。共包含九个不同通道的测点, 依次记为 P1~P9。

工件材料和加工参数根据工程实际设定, 详细信息见表 2。铣刀沿工件长边铣削一次, 九个测点分别采集一组数据。每完成八次铣削即采用 GP-300C 工业显微镜测量一次刀具的后刀面磨损量。根据 ISO 8688-1 中的刀具失效判据, 当后刀面磨损厚度超过 300 μm 时刀具失效, 即终止试验。

图 2 铣刀磨损试验台及测点布置

表 2 刀具磨损试验参数

主轴转速/ (r/min)	进给量/ (mm/min)	背吃刀量/ mm	工件 材质	工件尺寸/ mm ³
4 500	400	1.5	45 钢	100×60×60

图 4 九组测点数据的有效值指标

3.2 模型构建

首先根据刀具磨损退化趋势, 采用 AIC 准则选取退化速率函数 $\mu(x_{k-1}, t_k)$ 表达式为 $a \exp(bx_{k-1})$ 。为了验证提出方法的通用性, 选取不同的多源观测函数或多源映射函数构建三种模型, 预测刀具剩余寿命。模型 1 采用式(8)中的多源观测函数, 其中 $\varphi(x_k, \theta_p)$ 同样采用 AIC 准则选为 x_k^c 。模型 2

六组失效刀具的磨损退化轨迹如图 3 所示, 图 3 中同样给出了一组刀具在三个不同磨损阶段的镜下观测结果。

图 3 刀具磨损退化轨迹

提取 9 个测点监测数据的有效值作为监测指标, 9 个监测指标在刀具全寿命期的变化曲线如图 4 所示。

采用多源映射函数中的线性回归模型 $g(Y_k) = a_0 + \sum_{p=1}^P a_p y_k^p + \varepsilon_k$ 。模型 3 采用 CNN 深度学习模型。

3.3 刀具剩余寿命预测

为验证提出的数模联动方法的有效性, 将提出方法与一种数据驱动的多传感器融合预测方法^[27]进行比较, 该方法采用函数主分量分析进行测点融合预测,

简称为 FPCA 方法。采用留一法交叉验证对六组刀具剩余寿命进行逐个预测。提出方法对应三种模型和 FPCA 方法的剩余寿命预测结果如图 5 所示。从六组

刀具的寿命预测结果曲线可以看出, 提出方法对应三种模型预测结果相比于 FPCA 方法预测结果更加逼近真实值, 因此提出方法得到了更加准确的预测结果。

图 5 刀具剩余寿命预测结果比较

为对结果进行定量比较, 计算预测结果的 WRE 值, 如图 6 所示。可以看出, 提出方法的预测精度普遍优于 FPCA 方法。另外, 对于刀具 3、4 和 5, 模型 1 预测精度最高; 对于刀具 1, 模型 2 预测精度最高; 对于刀具 2 和 6, 模型 3 预测精度最高。该现象说明三种模型对不同样本退化趋势的表达力各有优劣, 采用特定类型的模型很难对所有样本都获得最优的预测结果。这也进一步说明了提出的方法框架的重要性。在统一方法框架的指导下, 可以构造多种不同类型的模型, 实现对不同样本退化趋势的准确描述。

图 6 刀具剩余寿命预测结果 WRE 比较

4 结论

(1) 提出了一种融合多传感器数据的数模联动物机械剩余寿命预测方法, 采用通用的 Wiener 随机退

化模型描述机械状态退化过程, 分别构建多源观测函数和多源映射函数对健康状态与数据间的因果关系和关联关系进行了解释, 通过粒子滤波算法实现数据与模型的联合动态匹配, 融合多传感器数据预测剩余寿命。

(2) 在提出方法框架指导下, 选取三种不同模型, 实现了对刀具剩余寿命的预测, 通过与其他方法进行比较验证了提出方法的有效性。

(3) 预测结果表明不同模型对不同样本退化趋势的表达力存在差异, 因此后续将会进行最优模型选择的研究, 寻找模型与样本之间的最优适配关系, 进一步完善提出的方法。

参 考 文 献

- [1] 李铭, 谢里阳, 张宇, 等. 齿轮的概率寿命预测与弯曲疲劳试验[J]. 机械工程学报, 2017, 53(18): 169-175.
LI Ming, XIE Liyang, ZHANG Yu, et al. Probabilistic life prediction and bending fatigue test for gear[J]. Journal of Mechanical Engineering, 2017, 53(18): 169-175.
- [2] 何正嘉, 曹宏瑞, 瞿艳阳, 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 Yanyang, et al. Developments and thoughts on operational reliability assessment of mechanical equipment[J]. Journal of Mechanical Engineering, 2014, 50(2): 171-186.

- [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] GE Digital. Predix platform[EB/OL]. [2021-07-23]. <https://www.ge.com/digital/iiot-platform>.
- [5] Rolls-Royce. Data innovation[EB/OL]. [2021-07-23]. <https://www.rolls-royce.com/media/our-stories/innovation/2017/data-innovation.aspx#challenge>.
- [6] LEI Y. Intelligent fault diagnosis and remaining useful life prediction of rotating machinery[M]. Oxford: Butterworth-Heinemann, 2016.
- [7] 张小丽, 陈雪峰, 李兵, 等. 机械重大装备寿命预测综述[J]. *机械工程学报*, 2011, 47(11): 100-116.
ZHANG Xiaoli, CHEN Xuefeng, LI Bing, et al. Review of life prediction for mechanical major equipments[J]. *Journal of Mechanical Engineering*, 2011, 47(11): 100-116.
- [8] PARIS P, ERDOGAN F. A critical analysis of crack propagation laws[J]. *Journal of Basic Engineering*, 1963, 85: 528-533.
- [9] LEI Y, LI N, GONTARZ S, et al. A model-based method for remaining useful life prediction of machinery[J]. *IEEE Transactions on Reliability*, 2016, 65(3): 1314-1326.
- [10] 赵申坤, 姜潮, 龙湘云. 一种基于数据驱动和贝叶斯理论的机械系统剩余寿命预测方法[J]. *机械工程学报*, 2018, 54(12): 115-124.
ZHAO Shenkun, JIANG Chao, LONG Xiangyun. Remaining useful life estimation of mechanical systems based on the data-driven method and bayesian theory[J]. *Journal of Mechanical Engineering*, 2018, 54(12): 115-124.
- [11] ZHANG C, TEE K F. Application of gamma process and maintenance cost for fatigue damage of wind turbine blade[J]. *Energy Procedia*, 2019, 158: 3729-3734.
- [12] 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.
- [13] 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.
- [14] LIU J, VITELLI V, ZIO E, et al. A novel dynamic-weighted probabilistic support vector regression-based ensemble for prognostics of time series data[J]. *IEEE Transactions on Reliability*, 2015, 64(4): 1203-1213.
- [15] 雷亚国, 陈昊, 李乃鹏, 等. 自适应多核组合相关向量机预测方法及其在机械设备剩余寿命预测中的应用[J]. *机械工程学报*, 2016, 52(1): 87-93.
LEI Yaguo, CHEN Wu, LI Naipeng, et al. A relevance vector machine prediction method based on adaptive multi-kernel combination and its application to remaining useful life prediction of machinery[J]. *Journal of Mechanical Engineering*, 2016, 52(1): 87-93.
- [16] XIA M, LI T, SHU T, et al. A two-stage approach for the remaining useful life prediction of bearings using deep neural networks[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(6): 3703-3711.
- [17] 丁显, 徐进, 滕伟, 等. 基于 RF 和 ANFIS 算法的直驱风电机组故障预警[J]. *噪声与振动控制*, 2018, 38(1): 209-214.
DING Xian, XU Jin, TENG Wei, et al. Failure prognostic prediction of direct drive wind turbines based on algorithms of random forest and adaptive network-based fuzzy inferer system[J]. *Noise and Vibration Control*, 2018, 38(1): 209-214.
- [18] 胡昌华, 施权, 司小胜, 等. 数据驱动的寿命预测和健康管理技术研究进展[J]. *信息与控制*, 2017, 46(1): 72-82.
HU Changhua, SHI Quan, SI Xiaosheng, et al. Data-driven life prediction and health management: State of the art[J]. *Information and Control*, 2017, 46(1): 72-82.
- [19] 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 Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. *Journal of Mechanical Engineering*, 2018, 54(5): 94-104.
- [20] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. *Reliability Engineering & System Safety*, 2018, 172: 1-11.
- [21] QIN Y, XIANG S, CHAI Y, et al. Macroscopic-microscopic attention in LSTM networks based on fusion features for gear remaining life prediction[J]. *IEEE Transactions on Industrial Electronics*, 2019, 67: 10865-10875.
- [22] NGUYEN H P, LIU J, ZIO E. A long-term prediction approach based on long short-term memory neural networks

- 作者简介:** 金鹏, 男, 1987 年出生, 博士后。主要研究方向为物体三维重建技术。
- E-mail: kingpeng604@163.com
- 刘少丽(通信作者), 女, 1984 年出生, 博士, 副教授, 博士研究生导师。主要研究方向为数字化检测与机器视觉。
- E-mail: liushaoli@bit.edu.cn
- 方玥, 女, 1984 年出生, 博士, 副研究员。主要研究方向为轨道检测与机器视觉。
- E-mail: fangyue@rails.cn

with automatic parameter optimization by Tree-structured Parzen estimator and applied to time-series data of NPP steam generators[J]. Applied Soft Computing, 2020, 89: 106116.

[23] WANG B, LEI Y, LI N, et al. Deep separable convolutional network for remaining useful life prediction of machinery[J]. Mechanical Systems and Signal Processing, 2019, 134: 106330.

[24] LI X, ZHANG W, DING Q. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction[J]. Reliability Engineering & System Safety, 2019, 182: 208-218.

[25] WANG D, ZHAO Y, YANG F, et al. Nonlinear-drifted Brownian motion with multiple hidden states for remaining useful life prediction of rechargeable batteries[J]. Mechanical Systems and Signal Processing,

- 作者简介:** 李乃鹏, 男, 1991 年出生, 博士, 讲师。主要研究方向为机械装备状态监测、剩余寿命预测与智能运维方法。
- E-mail: naipengli@mail.xjtu.edu.cn
- 雷亚国(通信作者),** 男, 1979 年出生, 博士, 教授, 博士研究生导师。主要研究方向为大数据智能故障诊断与寿命预测、机械系统建模与动态信号处理、机械装备健康监测与智能维护。
- E-mail: vaguolei@mail.xjtu.edu.cn