

DOI: 10.20189/j.cnki.CN/61-1527/E.202503011

半可观测状态的机床刀具剩余寿命 预测方法

骆南枝, 李乃鹏*, 王 淼, 雷亚国

(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, 陕西 西安 710049)

摘 要: 针对机床刀具在加工过程中系统状态需依赖多源传感器数据间接估计导致的剩余寿命预测精度不高的问题, 提出一种基于半可观测状态的机床刀具剩余寿命预测方法, 通过融合多源传感器数据与刀具系统状态信息, 构建了包含多源传感器数据映射偏差项的状态空间预测模型。首先, 利用回归网络建立多源传感器数据与刀具系统状态之间的非线性映射, 实现对半可观测系统状态的初步估计; 然后, 针对不同加工工况、退化模式及刀具类型所引起的数据分布差异, 提出系统状态回归误差补偿算法, 通过预测下一时刻状态估计的偏差值, 有效修正系统状态估计误差; 最后, 基于粒子滤波算法, 利用修正后的系统状态信息对刀具退化过程进行动态建模, 实现预测参数的自适应更新, 并采用刀具退化数据集进行了验证。结果表明: 所提方法在预测精度方面优于传统神经网络模型, 可有效提升机床刀具剩余寿命预测精度。

关键词: 剩余寿命预测; 半可观测系统; 状态修正; 粒子滤波

中图分类号: TJ410

文献标志码: A

文章编号: 2097-2741(2025)03-107-08

Semi-Observable State-Based Remaining Useful Life Prediction Method for Machine Tool Cutters

LUO Nanzhi, LI Naipeng*, WANG Miao, LEI Yaguo

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

ABSTRACT: A semi-observable state-based remaining useful life (RUL) prediction method for machine tool cutters was proposed to improve accuracy by addressing the limitations of indirect system state estimation based on multi-source sensor data during machining. A state-space prediction model with an embedded mapping deviation compensation term was constructed by integrating the multi-source sensor data with the tool system state information. First, a regression network was used to establish a nonlinear mapping between the multi-source sensor data and the tool system state, achieving an initial estimation of the semi-observable state. Subsequently, a

收稿日期: 2025-04-09

修回日期: 2025-04-26

录用日期: 2025-05-04

第一作者: 骆南枝 (2001—), 男, 硕士研究生, 主要从事机械装备寿命预测研究。E-mail: 1785848225@qq.com

***通信作者:** 李乃鹏 (1991—), 男, 副教授, 主要从事机械装备寿命预测、高端装备数字孪生建模研究。
E-mail: naipengli@mail.xjtu.edu.cn

引用格式: 骆南枝, 李乃鹏, 王淼, 等. 半可观测状态的机床刀具剩余寿命预测方法[J]. 火箭军工程大学学报, 2025, 39 (3): 107-114. LUO Nanzhi, LI Naipeng, WANG Miao, et al. Semi-observable state-based remaining useful life prediction method for machine tool cutters [J]. Journal of Rocket Force University of Engineering, 2025, 39 (3): 107-114.

system state regression error compensation algorithm was proposed to address the differences in data distribution caused by different processing conditions, degradation modes, and tool types. This algorithm achieved effective correction of system state estimation errors by predicting the deviation value of the state estimation at the next moment. Finally, based on a particle-filtering algorithm, the tool degradation process was dynamically modeled using the corrected system states. The prediction parameters were adaptively updated and validated using a tool degradation dataset. The results show that the proposed method outperforms traditional neural network models in prediction accuracy and significantly enhances the accuracy of the RUL prediction of machine tool cutters.

KEYWORDS: remaining useful life prediction; semi-observable system; state correction; particle filtering

机床刀具的剩余寿命预测作为提升加工效率、保障机床运行安全的关键技术,为降低维修成本、减少计划外停机时间和延长刀具使用寿命提供了理论基础和技术支撑^[1-3]。现有剩余寿命预测方法普遍假设刀具在运行过程中的系统状态是可持续观测的,然而在实际应用中,刀具的运行状态往往无法直接测量,通常只能在暂停加工或停机检查时才能获取部分状态信息,或依赖传感器数据间接表征,此类仅能获得部分状态信息的系统被称为半可观测系统^[4]。由于系统状态信息的获取具有间歇性、不连续性,且基于传感器信号的状态估计结果存在偏差,给刀具剩余寿命预测带来了极大挑战。

根据现有的研究,目前的预测解决方法大致可以分为3类,分别是基于物理模型预测方法、数据驱动预测方法和数据-模型联动预测方法。1) 基于物理模型的寿命预测研究方法通常对某一现象进行系统性建模以揭示其内在机理,具有较高的精度和良好的可解释性。Gupta等^[5]提出一种基于动态应力承载能力的滚动轴承寿命预测模型,并通过回归分析确定模型常数,提升了低应力条件下的寿命预测精度。Qian等^[6]将强化相空间翘曲方法与改进的Paris-Erdogan模型相结合,实现了对轴承缺陷的监测与剩余寿命预测。Lei等^[7]提出一种基于加权最小量化误差的新型系统退化指标,将Paris-Erdogan模型与粒子滤波算法结合,并通过极大似然法估计模型参数,实现了机械部件的剩余寿命预测。Yang等^[8]则采用疲劳裂纹扩展圆法,在较少的形状假设约束下,构建了受拉圆杆的三参数模型用于剩余寿命预测。2) 数据驱动预测方法主要依赖工业系统中获取的感知数据,通过统计分析或机器学习算法构建预测模型,刻

画系统状态的演化过程。此类方法能够在适用性、复杂性和预测精度之间取得平衡。典型的数据驱动方法包括神经网络、马尔可夫模型、自回归算法、随机模型以及贝叶斯网络等^[9-13]。Xiao等^[14]采用自适应时窗对滚动轴承的监测数据进行分段,并提取时窗特征作为前向反馈神经网络的输入,成功预测轴承的退化趋势。Guo等^[15]提出一种考虑趋势毛刺的新型卷积神经网络,构建了系统退化指标,实现了对滚动轴承剩余寿命的预测。Xia等^[16]提出一种基于降噪自动编码器的深度神经网络方法,能够将轴承监测信号划分为多个退化阶段,并提取关键特征用于预测滚动轴承的剩余寿命。迟骋等^[17]提出一种结合动态卷积、门控Transformer和自回归模型的混合性能评估方法,提升了对大型复杂设备时序数据的特征提取和预测能力。段磊光等^[18]通过构建无源无线采集系统获取复合多层石墨烯丁羟推进剂的交流阻抗谱,分析其与老化时间的关系,并利用BP神经网络在热加速老化条件下对推进剂寿命进行预测。3) 数据-模型联动预测方法融合物理模型与数据驱动模型的优势,为机械设备剩余寿命预测提供了新的思路,已逐渐成为主流的发展方向。An等^[19]提出一种基于贝叶斯推理和传感信号的在线刀具剩余寿命预测框架,采用Pairs模型描述刀具退化过程,通过迭代更新模型参数,实现对铣削刀具剩余寿命的精准预测。Zhang等^[20]提出一种基于粒子学习的在线剩余寿命预测方法,同时考虑了刀具磨损过程中的测量不确定性和固有随机性。Hanachi等^[21]提出的混合数据物理框架整合了Sipos经验磨损模型的输出与自适应神经模糊推理系统,有效减少了信号噪声和测量不确定性对剩余寿命预测精度的影响。Li等^[22]将高斯过程回归与

刀具磨损机制结合应用, 将可变切削参数下的刀具剩余寿命预测的平均绝对误差降低到总寿命的 5% 以下。

现有研究大多基于理想化假设, 未能充分考虑实际工程中刀具系统状态无法持续观测的情况。针对这一问题, 本文提出一种基于半可观测状态的机床刀具剩余寿命预测方法。通过构建具有半可观测系统特性的多源数据状态空间模型, 建立传感器观测信息与刀具系统状态之间的映射关系, 并对估计的系统状态进行动态修正。同时, 引入贝叶斯递推估计对刀具退化趋势进行建模, 有效降低预测了过程中的不确定性。主要贡献如下。

1) 提出了一种基于半可观测状态数据的回归误差补偿算法, 通过融合多源传感器数据与半可观测系统状态, 实现对系统状态估计结果的动态修正, 提高了系统状态估计的准确性。

2) 在状态空间模型的框架下, 构建多源数据与系统状态数据之间的映射关系, 结合粒子滤波算法实现了对预测过程的动态更新。

1 基础理论

1.1 弹性回归状态映射

弹性回归^[23]能够有效应对多重共线性或高维数据问题, 提供稳定且精确的回归结果。其损失函数为

$$\text{Loss} = \sum_{i=1}^n (x_i - y_i^T \beta)^2 + \lambda_1 \sum_{j=1}^p |\beta_j| + \lambda_2 \sum_{j=1}^p \beta_j^2 \quad (1)$$

式中: y_i 为多源数据特征; x_i 为第 i 个样本对应的状态值; β 为回归系数向量; λ_1 和 λ_2 分别为 Lasso 和 Ridge 回归的正则化参数。

通过对原始信号进行特征提取, 制作对应的数据集。假设数据集中共有 n 个样本, 每个样本包含 p 个特征, 定义特征矩阵 Y 与目标向量 X 分别为

$$Y = \begin{bmatrix} Y_1^T \\ Y_2^T \\ \vdots \\ Y_n^T \end{bmatrix} = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1p} \\ y_{21} & y_{22} & \cdots & y_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \cdots & y_{np} \end{bmatrix}, X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (2)$$

通过训练得到的弹性回归模型可用于估计系统当前的状态, 其表达式为

$$x_k = g(Y_k, \beta) + \varepsilon_k \quad (3)$$

式中: x_k 为 k 时刻的系统真实状态; Y_k 为 k 时刻对应的特征向量; $g(\cdot)$ 为弹性回归映射函数; ε_k 为映射误差。

1.2 粒子滤波状态估计

粒子滤波^[24]通过一组随机生成的粒子来近似系统的后验概率分布。每个粒子代表系统状态的一个可能值, 并具有一个相应的权重, 权重反映了该粒子与实际观测值的匹配程度。其基本流程如下。

1) 初始化粒子集

在初始阶段, 生成一组粒子 $\{x_0^{(i)} | i = 1, 2, \dots, N\}$, 其中每个粒子 $x_0^{(i)}$ 是从先验分布中抽取的样本。通常这些粒子根据系统的初始状态或历史数据生成, 权重初始化为相等的值, 即 $\omega_0^{(i)} = \frac{1}{N}$ 。

2) 预测步骤

在每一时刻 k , 基于上一时刻的状态和状态转移模型预测当前时刻粒子的状态。假设当前时刻的系统状态由状态转移函数 $f_k(\cdot)$ 进行描述, 因此预测步骤可以表示为

$$x_k^{(i)} = f_k(x_{k-1}^{(i)}, \theta_k, \omega_k) \quad (4)$$

式中: θ_k 为模型参数向量; ω_k 是系统噪声; $x_k^{(i)}$ 表示第 i 个粒子在 k 时刻的状态。

3) 更新步骤

在获得当前时刻的观测值 z_k 后, 通过观测模型 $h_k(x_k, v_k)$ 更新每个粒子的权重。粒子的权重根据观测值和预测值的匹配度进行更新, 权重更新公式为

$$\omega_k^{(i)} = \omega_{k-1}^{(i)} \cdot p(z_k | x_k^{(i)}) \quad (5)$$

式中: $p(z_k | x_k^{(i)})$ 为粒子 $x_k^{(i)}$ 对应的观测概率密度, 反映了该粒子与观测值之间的匹配度。

4) 归一化权重

为保证所有粒子的权重之和为 1, 需要对所有粒子的权重进行归一化处理, 以保证粒子权重在可控范围内, 不出现权重过大或者权重消失的情况, 表达式为

$$\omega_k^{(i)} \leftarrow \frac{\omega_k^{(i)}}{\sum_{i=1}^N \omega_k^{(i)}} \quad (6)$$

5) 重采样

在每一轮迭代中, 由于粒子权重的分布可能不均匀, 导致某些粒子权重过高, 而其他粒子的权重则趋近于零。为避免粒子退化问题, 通常需要进行重采样步骤, 重新生成粒子集合, 重采样的过程可以通过如下步骤实现。

①根据粒子权重进行抽样, 生成新的粒子集;

②使得每个粒子的权重初始化为 $\frac{1}{N}$ 。

6) 估计系统状态

系统状态的估计可以通过对粒子加权平均得到。当前时刻的状态估计 $\hat{x}_k$ 可表示为

$$\hat{x}_k = \sum_{i=1}^N \omega_k^{(i)} x_k^{(i)} \quad (7)$$

所得的加权平均值即为当前时刻系统状态的最优估计。

2 基于半可观测状态的机床刀具剩余寿命预测方法

所提的基于半可观测状态的机床刀具剩余寿命预测方法整体流程如图1所示。首先,利用离线阶段获取的多源传感器数据与半可观测刀具系统状态数据对回归网络进行初始化,实现对机床刀具退化特征的初步建模,并在实际加工过程中,接收到新样本时动态更新网络参数,以提升模型的泛化能力。随后,利用训练好的回归模型对当前传感器观测数据进行映射,获得刀具运行状态的估计值,并采用提出的回归误差补偿算法对该估计值进行修正,以降低由工况变化、退化模式差异等引起的系统偏差。最终,将修正后的刀具状态输入粒子滤波框架,对其退化过程进行动态建模,并在设定退化阈值的基础上推导刀具的剩余寿命概率密度函数。




图1 预测框架流程

Fig. 1 Flow chart of prediction frame

2.1 系统状态回归误差补偿算法

在实际工程应用中,机床刀具的运行状态监

测通常采用在线传感器实时监测与人工定期检查相结合的策略。通过定期检查可获得刀具的系统状态信息,构成半可观测系统的观测基础。同时,实时采集的传感器数据可用于推测刀具当前的运行状态。将信息进行比对,可以评估系统状态估计值与系统实际状态之间的偏差。

为提升刀具系统状态估计的准确性,提出一种系统状态回归误差补偿算法。考虑到实际值与估计值之间的偏差未呈现出明确的单一趋势,因此,直接建模具有一定挑战性。该算法通过对未来时刻偏差值的变化趋势进行预测,从而实现当前状态估计的动态修正,有效减小系统误差。在有限时间窗口内,偏差的变化趋势可能呈现线性、对数、指数或幂函数等不同形式,但具体的演化规律往往难以提前确定。因此,本文采用多种函数模型对偏差序列进行拟合,并基于最优拟合结果估计下一时刻的偏差值,从而更准确地刻画偏差演化过程,提高系统状态估计的稳定性与精度。

设有 r 个拟合函数,分别表示为 $\varphi_1(t, \boldsymbol{\vartheta}_1)$, $\varphi_2(t, \boldsymbol{\vartheta}_2)$, $\dots$, $\varphi_r(t, \boldsymbol{\vartheta}_r)$, 其中,每个拟合函数的参数向量分别为 $\boldsymbol{\vartheta}_1, \boldsymbol{\vartheta}_2, \dots, \boldsymbol{\vartheta}_r$ 。若第 i 个模型包含 d 个参数,则其参数表达为 $\boldsymbol{\vartheta}_i = (\theta_{i1}, \theta_{i2}, \dots, \theta_{id})^T$ 。定义真实状态和估计状态之间的偏差为 $\varepsilon_m = x_m - \hat{x}_m$, 对于给定的 m 个数据点 $\{(t_1, \varepsilon_1), (t_2, \varepsilon_2), \dots, (t_m, \varepsilon_m)\}$, 采用均方误差作为误差度量的函数,其计算表达式为

$$E_i = \sqrt{\frac{1}{m} \sum_{k=1}^m (\varepsilon_k - \varphi_i(t_k, \boldsymbol{\vartheta}_i))^2} \quad (8)$$

式中: E_i 为第 i 个拟合函数的偏差大小; k 为数据点的编号, $k = 1, 2, \dots, m$ 。

为确定最优拟合函数,需要比较不同函数的误差度量值。误差越小,证明其拟合效果越优。因此,最优拟合函数可通过最小化误差度量函数确定,其误差补偿项可表示为

$$\hat{\varepsilon}_{m+1} = \varphi_{\text{best}}(t_{m+1}, \boldsymbol{\vartheta}_{\text{best}}) \quad (9)$$

式中: $\hat{\varepsilon}_{m+1}$ 为 t_{m+1} 时刻的误差补偿项; $\varphi_{\text{best}}(\cdot)$ 为最优拟合函数; $\boldsymbol{\vartheta}_{\text{best}}$ 为对应的拟合参数。

状态估计值的校正旨在适应动态工况变化,提高后续预测精度。修正过程中,所选函数形式主要包括但不限于以下3种。

1) 线性函数

$$\varphi(t) = at + b \quad (10)$$

2) 指数函数:

$$\varphi(t) = a^t + b \quad (11)$$

3) 幂函数:

$$\varphi(t) = t^a + b \quad (12)$$

式中: a 和 b 为常数, 在系统状态修正过程中, 通过最大释然估计来确定拟合函数的参数。

2.2 基于半可观测系统的状态空间模型

为准确刻画机床刀具退化过程中系统状态的动态演变, 基于半可观测状态的机床刀具剩余寿命预测方法构建了包含状态修正机制的预测模型。其状态转移过程可表示为

$$\mathbf{x}_k = f_k(\mathbf{x}_{k-1}, \theta_k, \omega_k) \quad (13)$$

式中: $\mathbf{x}_{k-1}$ 为上一时刻的状态向量, 即描述退化趋势的参数; $f_k(\cdot)$ 为状态传递函数, 定义为 $R^{n_x} \times R^{n_\omega} \rightarrow R^{n_x}$ 。

由于系统状态通常无法直接观测, 因此, 需要利用观测数据对状态进行估计。状态与观测值的关系可表示为

$$\mathbf{z}_k = h_k(\mathbf{x}_k, v_k) \quad (14)$$

式中: $\mathbf{z}_k$ 为系统在 k 时刻的观测值; $h_k(\cdot)$ 为观测函数, 定义为 $R^{n_x} \times R^{n_v} \rightarrow R^{n_z}$; v_k 为观测噪声。

在具体实现中, 系统状态由回归网络对多源传感器数据进行建模估计。然而, 受数据偏差与模型泛化误差影响, 回归结果可能存在系统性误差。因此, 引入回归误差补偿机制, 状态估计模型修正为

$$\mathbf{x}_k = g(\mathbf{Y}_k, \boldsymbol{\beta}) + \boldsymbol{\varphi}_{\text{best}}(t_k, \boldsymbol{\vartheta}_{\text{best}}) + \boldsymbol{\epsilon}_k \quad (15)$$

式中: $\boldsymbol{\varphi}_{\text{best}}(t_k, \boldsymbol{\vartheta}_{\text{best}})$ 为最优误差补偿项; $\boldsymbol{\epsilon}_k$ 为经过状态修正之后仍存在的误差。

为进一步提升状态估计的准确性, 采用贝叶斯滤波方法对状态进行推理。首先, 根据状态转移方程计算先验概率密度函数

$$p(\mathbf{x}_k | \mathbf{z}_{1:(k-1)}) = \int (\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{z}_{1:(k-1)}) d\mathbf{x}_{k-1} \quad (16)$$

当获得新的观测值 $\mathbf{z}_k$ 后, 利用贝叶斯公式更新状态的概率密度函数, 得到 k 时刻的后验概率密度函数为

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) = \frac{p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:(k-1)})}{p(\mathbf{z}_k | \mathbf{z}_{1:(k-1)})} \quad (17)$$

式中: $p(\mathbf{z}_k | \mathbf{z}_{1:(k-1)})$ 作为归一化因子, 可表示为

$$p(\mathbf{z}_k | \mathbf{z}_{1:(k-1)}) = \int (\mathbf{x}_k | \mathbf{z}_{1:(k-1)}) p(\mathbf{z}_k | \mathbf{x}_k) d\mathbf{x}_k \quad (18)$$

在机床刀具的退化过程中, 失效时间 T 可以定义为系统状态首次达到失效阈值 D 所需的时间,

其表达式为

$$T = \inf \{t: x(t) \geq D | t > 0\} \quad (19)$$

式中: $\inf \{\cdot\}$ 为下确界函数。

对于实时退化过程, 假设机床刀具在 t_k 时刻未失效, 则定义系统在 t_k 时刻达到失效阈值 D 所需的时间为剩余使用寿命 L_k , 计算表达式为

$$L_k = \inf \{l: x(l + t_k) \geq D | \mathbf{x}_k < D\} \quad (20)$$

式中: $x(l + t_k)$ 表示未来时刻 $l + t_k$ 处的系统退化状态。

3 实验验证

为验证所提的基于半可观测状态的机床刀具剩余寿命预测方法的有效性, 选取融合卷积神经网络与长短时记忆网络的典型深度学习预测方法作为对比方法, 使用刀具寿命退化数据集进行验证, 随机选取其中 5 个样本作为训练样本, 1 个样本作为测试样本, 对不同方法的预测结果进行对比验证。

3.1 实验设置

本次实验在 VMC850 加工中心^[25]上进行。表 1 列出了 VMC850 加工中心的部分技术参数, 所使用的工件材料为 45 钢。

表 1 实验参数设置

Table 1 Experimental parameter setting

参数	数值
转速	4 500 rpm
进给量	400 mm · min ⁻¹
切削深度	1.5 mm
工件尺寸	100 × 60 × 60 mm ³

本次实验共采集振动、力、声、电流和声发射 5 类信号。三向加速度传感器布置于主轴上 (轴向为 X 、切向为 Y 、径向为 Z), 三向测力仪布置于工件下方 (平行于主轴方向为 Z , 垂直于主轴方向为 Y , 平行于铣削方向为 X), 声传感器布置于工作台上, 电流传感器接主轴电机 U 相, 声发射传感器布置于工件旁。

刀具磨损值的测量采用工业相机拍摄刀具图像的方式, 在每层材料加工完成后进行图像获取和磨损判定, 确保磨损数据的准确性和采集过程的连续性。在不影响切削连贯性的前提下完成图像获取, 以尽可能减小测量误差。信号采集采用

实时记录方式,在每次切削过程中均记录传感器信号,采样频率为 10 kHz,单次采样时长为 5 s。每加工一层工件材料共进行 8 次切削操作,故每 8 组传感器数据对应 1 个磨损值。实验设定当刀具磨损值达到 300 μm 时失效。

3.2 预测结果及对比分析

为了客观评价模型的预测效果,采用均方根误差作为衡量标准,计算公式为

$$E_{\text{RMSE}} = \frac{1}{N} \sqrt{\sum_{i=1}^N (\text{VB}_i^{\text{p}} - \text{VB}_i^{\text{r}})^2} \quad (21)$$

式中: N 为测试样本总数; VB_i^{p} 为第 i 个样本的预测磨损值; VB_i^{r} 为第 i 个样本的真实磨损值。

在多源特征数据融合过程中,一定的偏差往往难以避免,该偏差定义为实际磨损值与拟合磨损值之间的差值。通过最近几个点的数据预测下一时刻的偏差,并据此评估预测结果的可信度。此外,在预测过程中,根据前一时刻的偏差引入误差修正项,并对误差项进行拟合,以刀具 1 为例,其有效性如图 2 所示。可以看出,所提的误差补偿算法能够较准确地逼近实际磨损偏差,展现出良好的误差补偿效果。




图 2 刀具 1 误差补偿效果对比

Fig. 2 Comparison of error compensation effect of cutter 1

将预测误差值与原始拟合值合并,以优化磨损曲线。刀具 1 优化后的磨损曲线与实际磨损曲线的对比如图 3 所示。可以明显看出,经过本文方法修正后的系统状态值与实际退化曲线更加吻合,显著提升了系统状态估计精度。

使用均方根误差对更新前后的系统状态退化曲线拟合效果进行定量评估,结果如表 2 所示。对比表中修正前后的拟合效果可以看出,所提的误差补偿方法能够有效修正系统状态。




图 3 刀具 1 系统状态修正效果

Fig. 3 Effect of system state correction of cutter 1

表 2 状态拟合效果 RMSE 对比

Table 2 Comparison of RMSE of state fitting effect

刀具序号	修正前	修正后
1	18.24	7.98
2	12.35	8.77
3	13.56	8.83
4	31.57	11.19
5	27.71	18.56
6	37.81	9.57

利用历史数据,通过弹性回归网络进行参数训练,并基于实时监测的系统状态对系统状态值进行校正与更新。然后,结合粒子滤波网络进行剩余寿命预测。刀具 1 剩余寿命预测结果如图 4 所示,可以看出,相较于卷积神经网络与长短时记忆网络融合的方法 (CNN-LSTM),所提方法在预测结果上更贴近实际寿命曲线,展现出更高的预测精度。




图 4 刀具 1 剩余寿命预测结果

Fig. 4 Results of remaining useful life prediction of cutter 1

为了对预测结果进行定量评估, 计算各方法预测曲线相对于真实退化曲线的均方根误差, 如图5所示。可以看出, 所提方法在预测精度上整体优于卷积神经网络与长短时记忆网络融合的方法。




图5 刀具剩余寿命预测 RMSE

Fig. 5 RMSE of remaining useful life prediction of cutters

4 结论

针对机床刀具加工过程中系统状态不可直接观测且状态估计精度受限的问题, 提出了一种基于半可观测状态的机床刀具剩余寿命预测方法。该方法融合多源传感器数据与有限系统状态信息, 构建状态空间模型以动态建模退化过程, 同时引入状态回归误差补偿机制以提升状态估计的准确性。通过结合粒子滤波框架, 实现了对刀具1剩余寿命的在线预测。主要结论如下。

1) 构建了一种融合多源传感器数据与系统状态信息的状态空间预测模型, 实现了对系统退化状态的高精度估计。

2) 提出了系统状态回归误差补偿算法, 针对样本间存在的工况差异、退化模式多样性及分布不一致等问题, 通过对状态估计偏差的建模与修正, 显著提升了模型的泛化能力与鲁棒性。

3) 将状态修正结果引入粒子滤波算法框架中, 实现了状态与模型参数的动态更新, 在应对非平稳退化过程时展现出了良好的预测稳定性。

参考文献

[1] LI N P, WANG M Y, LEI Y G, et al. A non-parametric degradation modeling method for remaining useful life prediction with fragment data[J]. Reliability Engineering & System Safety, 2024, 249: 110224.

[2] WANG Y, LEI Y G, LI N P, et al. Deep multisource parallel bilinear-fusion network for remaining useful life prediction of machinery[J]. Reliability En-

gineering & System Safety, 2023, 231: 109006.

[3] LI N P, XU P C, LEI Y G, et al. A self-data-driven method for remaining useful life prediction of wind turbines considering continuously varying speeds[J]. Mechanical Systems and Signal Processing, 2022, 165: 108315.

[4] LI N P, LEI Y G, GEBRAEEL N, et al. Multi-sensor data-driven remaining useful life prediction of semi-observable systems[J]. IEEE Transactions on Industrial Electronics, 2021, 68(11): 11482-11491.

[5] GUPTA P K, ZARETSKY E V. New stress-based fatigue life models for ball and roller bearings[J]. Tribology Transactions, 2018, 61(2): 304-324.

[6] QIAN Y, YAN R, GAO R X. A multi-time scale approach to remaining useful life prediction in rolling bearing[J]. Mechanical Systems and Signal Processing, 2017, 83: 549-567.

[7] LEI Y G, LI N P, 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.

[8] YANG Y L, CHU S, CHEN H. Prediction of shape change for fatigue crack in a round bar using three-parameter growth circles[J]. Applied Sciences, 2019, 9(9): 1751.

[9] SI X S, WANG W, HU C H, et al. A Wiener-process-based degradation model with a recursive filter algorithm for remaining useful life estimation[J]. Mechanical Systems and Signal Processing, 2013, 35(1-2): 219-237.

[10] 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.

[11] SI X S. An adaptive prognostic approach via nonlinear degradation modeling: application to battery data[J]. IEEE Transactions on Industrial Electronics, 2015, 62(8): 5082-5096.

[12] HERP J, PEDERSEN N L, NADIMI E S. Assessment of early stopping through statistical health prognostic models for empirical RUL estimation in wind turbine main bearing failure monitoring[J]. Energies, 2020, 13(1): 83.

[13] BIAN L K, GEBRAEEL N, KHAROUFEH J P. Degradation modeling for real-time estimation of residual lifetimes in dynamic environments[J]. IEEE Transactions, 2015, 47(5): 471-486.

[14] XIAO L, CHEN X H, ZHANG X H, et al. A

- novel approach for bearing remaining useful life estimation under neither failure nor suspension histories condition[J]. *Journal of Intelligent Manufacturing*, 2017, 28(8): 1893-1914.
- [15] GUO L, LEI Y G, LI N P, et al. Machinery health indicator construction based on convolutional neural networks considering trend burr[J]. *Neurocomputing*, 2018, 292: 142-150.
- [16] XIA M, LI T, SHU T X, et al. A two-stage approach for the remaining useful life prediction of bearings using deep neural networks[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(6): 3703-3711.
- [17] 迟骋, 李向阳, 张志利, 等. 基于动态卷积的混合模型性能评估方法[J]. *火箭军工程大学学报*, 2024, 38(5): 53-58, 80.
- CHI C, LI X Y, ZHANG Z L, et al. Performance evaluation method of hybrid model based on dynamic convolution[J]. *Journal of Rocket Force University of Engineering*, 2024, 38(5): 53-58, 80.
- [18] 段磊光, 霍怡伟, 郭剑锋, 等. 基于交流阻抗法的复合多层石墨烯丁羟推进剂老化监测研究[J]. *火箭军工程大学学报*, 2024, 38(3): 66-73.
- DUAN L G, HUO Y W, GUO J F, et al. Study on aging monitoring of composite multi-layer graphene HTPB propellant based on AC impedance method[J]. *Journal of Rocket Force University of Engineering*, 2024, 38(3): 66-73.
- [19] AN H, WANG G F, DONG Y, et al. Tool life prediction based on Gauss importance resampling particle filter[J]. *The International Journal of Advanced Manufacturing Technology*, 2019, 103(9): 4627-4634.
- [20] ZHANG J L, STARLY B, CAI Y, et al. Particle learning in online tool wear diagnosis and prognosis[J]. *Journal of Manufacturing Processes*, 2017, 28: 457-463.
- [21] HANACHI H, YU W N, KIM I Y, et al. Hybrid data-driven physics-based model fusion framework for tool wear prediction[J]. *The International Journal of Advanced Manufacturing Technology*, 2019, 101(9): 2861-2872.
- [22] LI D H, LI Y G, LIU C Q. Gaussian process regression model incorporated with tool wear mechanism[J]. *Chinese Journal of Aeronautics*, 2022, 35(10): 393-400.
- [23] ZHANG Z, LAI Z H, XU Y, et al. Discriminative elastic-net regularized linear regression[J]. *IEEE Transactions on Image Processing*, 2017, 26(3): 1466-1481.
- [24] DJURIC P M, KOTECHEA J H, ZHANG J, et al. Particle filtering[J]. *IEEE Signal Processing Magazine*, 2003, 20(5): 19-38.
- [25] WANG Y, LEI Y G, LI N P, et al. Deep multisource parallel bilinear-fusion network for remaining useful life prediction of machinery[J]. *Reliability Engineering & System Safety*, 2023, 231: 109006.

(编辑: 于福兴)