

DOI: 10.19650/j.cnki.cjsi.J2514551

面向频繁启停循环条件的滚动轴承剩余 使用寿命预测研究*

高晓旭¹, 樊 薇^{1,2}, 陈 超¹, 陈 龙³, 朱忠奎⁴

(1. 江苏大学机械工程学院 镇江 212013; 2. 中国矿业大学煤炭精细勘探与智能开发全国重点实验室 徐州 221116;
3. 江苏大学汽车工程研究院 镇江 212013; 4. 苏州大学轨道交通学院 苏州 215131)

摘 要:滚动轴承在频繁启停循环工况下的剩余使用寿命(RUL)预测受到工况频繁切换的影响,致使特征与退化状态的关联性弱化,且退化轨迹呈现周期性波动,传统方法难以构建有效健康指标。为此,一种基于 SA-PSO-STL 的虚拟健康指标构建方法被提出。首先,针对关联性弱化问题,采用结合模拟退火的粒子群优化算法(SA-PSO)筛选与退化状态强相关的敏感退化特征,以提取与轴承退化过程高度相关的特征信息,增强退化表征的单调性、趋势性、鲁棒性,并利用主成分分析(PCA)对优选特征进行融合;其次,针对退化轨迹的周期性波动干扰,引入 STL 分解提取退化趋势,剥离周期性波动与残差噪声,从而获得能够清晰、稳定表征全寿命退化过程的虚拟健康指标。在此基础上,构建基于稀疏高斯过程回归模型(SGPR)的自适应多阶段 RUL 预测模型。所提模型采用 3 组频繁启停循环工况下的轴承全寿命实验数据进行验证,实验研究显示,其构建的虚拟健康指标在 A、B、C 3 组数据上的综合评分分别为 0.955 5、0.962 2 与 0.989 2;RUL 预测在对应数据上的均方根误差(RMSE)分别为 0.106、0.047 与 0.014,平均绝对误差(MAE)分别为 0.012、0.002 与 0.002,上述定量指标均明显优于所有对比模型,充分证明了该模型在频繁启停循环工况下强化退化趋势表征、提高轴承剩余使用寿命预测精度方面的有效性与创新性。

关键词: 频繁启停循环工况; 剩余使用寿命预测; STL 分解; 稀疏高斯过程回归; 多阶段退化模型

中图分类号: TH133.3 **文献标识码:** A **国家标准学科分类代码:** 460.40

The remaining useful life prediction research for rolling bearings under frequent start-stop cycle conditions

Gao Xiaoxu¹, Fan Wei^{1,2}, Chen Chao¹, Chen Long³, Zhu Zhongkui⁴

(1. School of Mechanical Engineering, Jiangsu University, Zhenjiang 212013, China; 2. The State Key Laboratory for Fine Exploration and Intelligent Development of Coal Resources, China University of Mining and Technology, Xuzhou 221116, China; 3. Automotive Engineering Research Institute, Jiangsu University, Zhenjiang 212013, China; 4. School of Rail Transportation, Soochow University, Suzhou 215131, China)

Abstract: The remaining useful life (RUL) prediction of rolling bearings under frequent start-stop cycle conditions is affected by the frequent switching of working conditions, which results in the weakened correlations between features and degradation states as well as periodic fluctuations of degradation trajectory. These issues make it difficult for traditional methods to construct effective health indicators. Accordingly a virtual health indicator construction method based on SA-PSO-STL is proposed to address this issue. For the weakened correlation problem, a simulated annealing particle swarm optimization (SA-PSO) algorithm is used to screen sensitive degradation features strongly correlated with degradation states. This process extracts feature information highly relevant to the bearing degradation process, thereby enhancing the monotonicity, trendability, and robustness of degradation representations. Then the principal component analysis (PCA) is utilized to fuse the selected features. Furthermore in order to mitigate the interference of periodic fluctuations in the degradation trajectory, the seasonal and trend decomposition based on the loess (STL) is employed for extracting the trend and separating periodic fluctuations as well as residual noise, thereby obtaining the virtual health indicators that can clearly and stably characterize the entire life

收稿日期: 2025-10-02 Received Date: 2025-10-02

* 基金项目: 煤炭精细勘探与智能开发全国重点实验室开放研究课题(SKLCRSM24KF009)项目资助

cycle degradation process. Finally an adaptive multi-stage degradation model based on the sparse gaussian process regression (SGPR) is performed for the remaining useful life prediction. The experimental validation is conducted using three sets of full life cycle bearing data under different frequent start-stop cycle conditions. The results show that the constructed virtual health indicator (VHI) achieves comprehensive evaluation scores of 0.955 5, 0.962 2, and 0.989 2 on datasets A, B, and C respectively, while the corresponding RUL predictions demonstrate root mean square errors (RMSE) of 0.106, 0.047, and 0.014, as well as mean absolute errors (MAE) of 0.012, 0.002, and 0.002, respectively. It's found that all quantitative indicators are significantly superior to all comparison models, which demonstrate the effectiveness and innovation of proposed model in enhancing the characterization of degradation trends and improving the prediction accuracy of bearing remaining useful life under frequent start-stop cycle conditions.

Keywords: frequent start-stop cycle condition; remaining useful life prediction; seasonal and trend decomposition using loess; sparse gaussian process regression; multi-stage degradation model

0 引言

旋转机械在现代工业中无处不在,滚动轴承作为关键承载部件,其健康状态直接关系到整机的可靠性与寿命^[1]。在实际应用中,风力发电机、矿山机械、数控机床等设备普遍存在频繁启停循环。这类工况一方面引入大量与退化无关的瞬态冲击与工况切换信息,削弱特征与退化状态的关联性;另一方面,由于每天停机-重启的重复模式,轴承退化轨迹呈现明显的周期性波动,使传统健康指标难以保持单调性,从而降低剩余使用寿命(remaining useful life, RUL)预测的精度与鲁棒性^[2]。因此,研究适用于频繁启停循环工况的轴承健康状态评估方法,对提升旋转机械设备寿命预测准确性具有重要意义。

针对频繁启停循环工况下的寿命预测,直接相关的研究尚显不足,现有工作多集中于对单一或特定模式的启停过程进行物理损伤机理建模与损伤评估。例如,王福民^[3]通过数据物理混合建模对频繁启停下的汽轮机汽缸结构进行低周疲劳寿命预测;张青雷等^[4]面向拉杆转子在多种启停过程中进行疲劳损伤评估,明确其寿命损耗率演变规律;王丽媛^[5]针对建立三维有限元模型在快速启停工况下的锅炉汽包疲劳寿命开展预测研究。然而,基于物理模型的方法严重依赖部件精确机理,普适性较差,难以应用于在线状态监测与实时预测。随着数据获取能力的提升,研究重点逐渐转向数据驱动方法。近年来,数据驱动尤其是深度学习方法在持续不变工况下的滚动轴承寿命预测取得显著进展^[6]。然而,工业设备常运行于更为复杂的变工况下,其负载、转速等运行参数的动态变化给寿命预测带来了新的挑战。为此,研究者们针对变工况采用了域对抗神经网络(domain adversarial neural networks, DANN)^[7]、长短期记忆网络(long short term memory, LSTM)^[8]、以及注意力机制^[9]等数据驱动方法进行寿命预测。典型的数据驱动方法通常包含:数据采集、健康指标(health indicator, HI)构建和剩余使用

寿命 RUL 预测模型构建。其中,HI 通过对多维特征进行提取与融合形成虚拟健康指标,其质量直接决定后续预测性能^[10]。然而,现有数据驱动方法在面对频繁启停循环这类特殊变工况时,适用性仍存在不足:工况频繁切换导致特征提取与关联建模不稳定,周期性波动又破坏了 HI 的单调退化假设。直接将常规 HI 用于 RUL 预测,往往造成误判与不确定性提升。

围绕“特征-退化关联性弱化”问题,已有工作多从特征筛选与表示学习入手^[11]:如 Guo 等^[12]计算所有特征指标与寿命的相关性并输入循环神经网络模型,筛选出表现轴承退化状态的健康指标。王久健等^[13]提出一种基于卷积长短期记忆深度神经网络的健康指标构建模型,挖掘反映退化性能的特征并结合双指数寿命模型实现 RUL 预测。Hong 等^[14]运用小波包分解、经验模态分解筛选出与退化状态强相关的特征,和自组织映射网络融合生成健康指标。然而,深度学习普遍依赖大规模高质量标注数据^[15],且在工况切换频繁场景下泛化性受限;同时,传统启发式优化易陷入局部最优,难以在高维组合空间中实现稳健的全局搜索。因此,亟需兼具全局寻优能力与对工况波动适应性的动态特征筛选策略。针对此选择模拟退火粒子群优化(simulated annealing particle swarm optimization, SA-PSO)作为特征筛选策略^[16-17],其融合了粒子群(particle swarm optimization, PSO)的全局搜索与模拟退火(simulated annealing, SA)的逃逸局部最优能力,旨在从高维波动特征中稳定地筛选出与退化状态强相关的敏感特征。

针对“周期性波动干扰”问题,时序分解通过将序列分解为趋势、季节(周期)和残差分量,为提取本质退化趋势提供了有效思路^[18]。然而,基于固定基函数的传统分解(如简单傅里叶分解)难以应对启停引起的非平稳与时变季节性信号,无法准确分解出时变季节性干扰下的稳定趋势项^[19]。相较之下,STL(seasonal and trend decomposition using loess)分解基于局部加权回归(loess),可自适应刻画时变季节项并稳健提取趋势分量,已在多类复杂工业信号中表现出优势^[20]。李晋国等^[21]

应用 STL 分解结合门控循环单元 (gated recurrent unit, GRU) 模型,有效捕获时间序列的局部和全局信息,显著提升预测精度。王晓燕等^[22]采用 STL 将数控机床原始故障数据分解,分别建模后再融合,凸显 STL 在复杂信号分离中的优势。李逸航等^[23]采用 STL 将原有光伏功率序列进行分解,得到光伏输出区间预测结果。因此,利用 STL 分解从频繁启停循环工况下的复杂信号中剥离出周期性扰动与随机噪声,提取表征轴承性能退化趋势的趋势项,是有效提升频繁启停循环工况下轴承的退化健康指标可用性的重要途径之一。选用 STL 正是基于其对信号周期性干扰的自适应能力与对异常值的鲁棒性,能有效处理频繁启停循环产生的复杂波动^[20]。

在 RUL 预测模型方面,高斯过程回归 (Gaussian process regression, GPR) 作为具有概率输出能力的非线性模型,在 RUL 预测中广泛应用^[24]。然而,在频繁启停循环工况下,工况切换会诱发长序列、多阶段非平稳退化特性,导致传统 GPR 面临两方面挑战:一方面是随着数据序列增长,计算复杂度显著上升;另一方面是模型难以自适应不同退化阶段间的动态特性变化。为此,稀疏高斯过程回归 (sparse Gaussian process regression, SGPR) 模型通过引入诱导点,在保持传统 GPR 模型性能的同时显著提高计算效率,提升多阶段退化模型的鲁棒性和准确性^[25]。因此,构建自适应多阶段的 SGPR 模型,可更好地捕捉频繁启停循环工况下的退化动态,从而提升 RUL 预测的准确性。采用 SGPR,既能降低计算成本,又能提供 RUL 预测不确定性量化,适应频繁启停循环工况下退化不确定性^[25]。

综合而言,本研究核心创新性贡献为针对频繁启停循环工况下特征关联性弱化与退化轨迹周期性波动两大核心挑战,提出一个融合动态特征筛选、时变周期性波动剥离与自适应多阶段寿命预测的集成框架。具体而言,本研究提出一种基于 SA-PSO-STL 的虚拟健康指标构建与预测框架,包括以下两个核心部分:

- 1) 提出基于 SA-PSO-STL 的虚拟健康指标构建方法。通过 SA-PSO 进行全局特征筛选,获得与退化状态强相关的敏感特征;针对退化轨迹周期性波动干扰问题,引入 STL 分解提取稳定趋势项,获取能清晰、稳定表征性能退化全过程的虚拟健康指标。
- 2) 建立基于稀疏高斯过程回归的自适应多阶段 RUL 预测模型。通过自适应多阶段变化点检测与自适应核函数选择,提高不同退化阶段 RUL 预测的准确性和鲁棒性。
- 基于 3 组频繁启停循环工况下轴承全寿命实验数据开展验证与对比,结果表明所提方法在退化趋势表征与 RUL 预测精度方面均优于对比基线,体现出良好的工程适用性与稳健性。

1 基于 SA-PSO-STL 的虚拟健康指标构建

针对频繁启停循环工况下轴承特征—退化关联性弱化与退化轨迹周期性波动难题,一种基于 SA-PSO-STL 的虚拟健康指标 (virtual health indicator, VHI) 构建方法被提出,整体流程如图 1 所示,包含特征提取、模拟退火粒子群优化特征筛选、主成分分析融合和 STL 分解 4 部分。




图 1 基于 SA-PSO-STL 构建虚拟健康指标流程
Fig. 1 Flow chart of constructing virtual health indicators based on SA-PSO-STL

1.1 特征提取

退化指标的本质是对设备渐进性退化的表征,其随时间的演化能够揭示轴承的退化轨迹^[10]。如表 1 所示,从原始信号中提取 31 个候选特征,包括时域特征、频域特征、时频域特征和熵特征 4 大类,用于后续退化指标的构建与筛选。

1.2 基于模拟退火粒子群优化的特征筛选

在频繁启停循环工况下,原始特征空间往往维度高、冗余多且混入工况瞬态噪声,导致特征与退化状态的统

表 1 原始特征集

Table 1 Original feature set

类型	特征	
时域特征	F1. 最大值	F2. 最小值
	F3. 峰值	F4. 峰峰值
	F5. 平均值	F6. 绝对平均值
	F7. 方根幅值	F8. 方差
	F9. 标准差	F10. 均方根
	F11. 峭度	F12. 偏度
频域特征	F13. 平均频率	F14. 重心频率
	F15. 频率均方根	F16. 频率标准差
时频域特征	F17~F24: 8 个频段能量比	
熵特征	F25. 样本熵	F26. 排列熵
	F27. 模糊熵	F28. 能量熵
	F29. 信息熵	F30. 小波能量熵
	F31. 小波奇异谱熵	

计关联被削弱。为此,采用模拟退火粒子群优化算法进行敏感特征筛选,旨在从原始高维特征空间中,寻找到与轴承性能退化过程相关性强、趋势表征稳定的最优特征子集^[26],在筛选完成后通过 PCA (principal component analysis) 进行特征融合,得到初始健康序列^[27]。

1) 模拟退火粒子群优化算法原理

SA-PSO 有效融合了 PSO 的全局寻优能力和 SA 算法的概率接受机制,可有效缓解 PSO 后期易陷入局部最优的缺陷^[16-17]。在 PSO 中,每个粒子对应一个候选特征子集,种群通过跟踪个体历史最优位置和群体全局最优位置在解空间迭代搜索。其核心速度与位置更新公式如式(1)和(2)所示。

$$V_i^{(t+1)} = \omega \times V_i^{(t)} + c_1 r_1 (P_{best,i}^{(t)} - X_i^{(t)}) + c_2 r_2 (G_{best}^{(t)} - X_i^{(t)})$$

(1)

$$X_i^{(t+1)} = X_i^{(t)} + V_i^{(t+1)}$$

(2)

其中, $X_i^{(t)}$ 和 $V_i^{(t)}$ 分别表示第 i 个粒子在第 t 次迭代时的位置和速度; ω 为惯性权重,平衡全局与局部搜索能力; c_1 、 c_2 为学习因子; r_1 、 r_2 是 $[0,1]$ 范围内的随机数; P_{best} 为个体历史最优位置, G_{best} 为群体全局最优位置。

为克服 PSO 易陷入局部最优的缺陷,SA-PSO 在每次迭代更新后引入模拟退火的麦尔特罗夫准则来判断是否接受粒子的新位置。该准则以一定概率接受恶化解,从而增强全局探索能力。接受概率 p 如式(3)所示。

$$p = \begin{cases} 1, & f_{new} \leq f_{old} \\ \exp\left(-\frac{f_{new} - f_{old}}{T}\right), & f_{new} > f_{old} \end{cases}$$

(3)

其中, f_{new} 和 f_{old} 分别代表粒子在新位置 and 原位置的适应度值, T 为当前温度,按冷却计划 $T_{k+1} = \alpha \cdot T_k$ 递减, α 为降温系数 ($0 < \alpha < 1$)。

2) 目标函数设计

特征筛选的目标是获得一个使健康序列单调、趋势明确且对噪声鲁棒的特征子集。为此,构建综合适应度函数^[28]如式(4)所示。

$$F = \beta_1 Mon(f) + \beta_2 Tre(f) + \beta_3 Rob(f)$$

(4)

其中, $\beta = [\beta_1, \beta_2, \beta_3]$ 为权重系数向量,其值由熵权法^[29]决定。 f 为退化指标向量。

单调性 $Mon(f)$ 、趋势性 $Tre(f)$ 和鲁棒性 $Rob(f)$ 表达式如式(5) ~ (7) 所示。

$$Mon(f) = \frac{1}{N-1} \left| NO.of\left(\frac{d}{df} > 0\right) - NO.of\left(\frac{d}{df} < 0\right) \right|$$

(5)

$$Tre(f) = \frac{N\left(\sum_{i=1}^N f_i t_i\right) - \left(\sum_{i=1}^N f_i\right)\left(\sum_{i=1}^N t_i\right)}{\sqrt{\left[N\sum_{i=1}^N f_i^2 - \left(\sum_{i=1}^N f_i\right)^2\right]\left[N\sum_{i=1}^N t_i^2 - \left(\sum_{i=1}^N t_i\right)^2\right]}}$$

(6)

$$Rob(f) = \frac{1}{N} \sum_{i=1}^N \exp\left(-\left|\frac{f_i - res(f_i)}{f_i}\right|\right)$$

(7)

其中, t_i 为时间步长, f_i 为在 t_i 时刻观察到的退化指标值, N 为退化指标序列的长度, $\frac{d}{df} = f_{i+1} - f_i$, $NO.of\left(\frac{d}{df} > 0\right)$ 和 $NO.of\left(\frac{d}{df} < 0\right)$ 分别表示正、负差异个数。退化指标的平均趋势 $res(f_i)$ 通过平滑技术^[30]得到。基于式(4) ~ (7),SA-PSO 在高维特征空间全局搜索,得到最优特征子集,筛选流程如图 2 所示。




图 2 基于 SA-PSO 特征筛选流程

Fig. 2 Flow chart of feature screening based on SA-PSO

1.3 STL 分解

STL 分解是一种对非平稳、时变季节性具有良好适应性的分解方法,其核心优势在于能够通过局部加权回归(loess)在存在异常值与周期波动时仍能稳健地提取趋势项。其对于频繁启停循环工况下由工况切换(如每日启停)诱发的周期性波动具有良好的剥离能力^[18]。

STL 分解将时间序列 $\{Y_t\}$ 分解为 3 个加性成分如式(8)所示。

$$Y_t = T_t + S_t + R_t \quad (8)$$

其中, T_t 代表趋势项,反映缓慢、单调的退化过程; S_t 代表季节项,对应启停带来的周期性扰动; R_t 代表残差项,包含了序列中的随机噪声和异常点。

分解过程通过内外循环嵌套实现。内循环负责精确计算趋势项与季节项。在每次迭代中,首先式(9)通过周期子序列平滑得到初步季节项 $C_t^{(k+1)}$,即:

$$C_t^{(k+1)} = \text{Loess}_{\text{seasonal}}(Y_t - T_t^{(k)}) \quad (9)$$

其中, (k) 表示第 k 次迭代的估计值, $\text{Loess}_{\text{seasonal}}$ 为季节平滑函数,对周期子序列进行局部加权回归。

然后通过低频滤波得到如式(10)所示的最终季节项 $S_t^{(k+1)}$,即:

$$S_t^{(k+1)} = C_t^{(k+1)} - \text{Loess}_{\text{lowpass}}(C_t^{(k+1)}) \quad (10)$$

其中, $\text{Loess}_{\text{lowpass}}$ 为低通滤波函数,移除季节项中的低频趋势分量。

随后,从去季节序列 $Y_t - S_t^{(k+1)}$ 中,通过 loess 平滑提取如式(11)所示的新的趋势项 $T_t^{(k+1)}$,即:

$$T_t^{(k+1)} = \text{Loess}_{\text{trend}}(Y_t - S_t^{(k+1)}) \quad (11)$$

其中, $\text{Loess}_{\text{trend}}$ 为趋势平滑函数,捕获序列的长期变化趋势。

外循环负责提升模型稳健性。在内循环收敛后,根据最终残差 R_t 的大小计算鲁棒性权重 ρ_t ,并赋予每个数据点,如式(12)所示。

$$\rho_t = B\left(\frac{|R_t|}{6 \cdot \text{median}(|R_t|)}\right) \quad (12)$$

其中, $B(\cdot)$ 为双平方权函数,用于降低异常值的权重, $\text{median}(|R_t|)$ 为 $|R_t|$ 的中位数。该权重将融入下一次内循环的所有 loess 平滑过程中,从而自动抑制异常值的影响。

经过完整的分解,高频的季节性波动与随机噪声被有效剥离,所得趋势项 T_t 即为最终的虚拟健康指标。

2 基于稀疏高斯过程回归的自适应多阶段轴承剩余使用寿命预测

2.1 自适应多阶段变化点检测

轴承退化过程往往呈明显的多阶段特征。基于已构

建的虚拟健康指标,进行自适应多阶段变化点检测。综合采用二值分割(binary segmentation, BS)、退化角(degradation angle, DA)和指数加权移动平均(exponentially weighted moving average, EWMA)3种方法,以均方误差(mean squared error, MSE)为评价准则,同时引入隐马尔可夫模型(hidden Markov model, HMM)对阶段数进行模型选择与优化。

MSE 的计算公式如式(13)所示。

$$\begin{aligned} \text{MSE} = & \frac{1}{\tau_1} \sum_{i=1}^{\tau_1} (v_i - \bar{v}_1)^2 + \frac{1}{\tau_2 - \tau_1 + 1} \sum_{i=\tau_1+1}^{\tau_2} (v_i - \bar{v}_2)^2 + \\ & \dots + \frac{1}{n - \tau_j + 1} \sum_{i=\tau_{j-1}+1}^n (v_i - \bar{v}_j)^2 \end{aligned} \quad (13)$$

其中, $\{\bar{v}_1, \bar{v}_2, \dots, \bar{v}_j\}$ 表示每个阶段数据点的平均值,每阶段根据检测的 j 个变化点位置 $\{\tau_1, \tau_2, \dots, \tau_j\}$ 对时间序列进行分割得到。

HMM 通过双重随机过程描述退化状态演变,采用广义向前向后算法估计模型参数,并通过维特比算法解码最优状态序列,从而确定变点数量与位置^[31]。其核心由状态转移概率矩阵 $\mathbf{A}$ 和观测概率矩阵 $\mathbf{B}$ 确定,如式(14)、(15)所示。

$$\mathbf{A} = [a_{ij}]_{H \times H}, a_{ij} = P(q_{t+1} = s_j | q_t = s_i) \quad (14)$$

$$\mathbf{B} = [b_j(k)]_{H \times M}, b_j(k) = P(o_t = v_k | q_t = s_j) \quad (15)$$

其中, a_{ij} 表示从状态 s_i 转移到状态 s_j 的概率, $b_j(k)$ 表示在状态 s_j 下观测到符号 v_k 的概率; q_t 表示 t 时刻的隐藏状态, o_t 表示 t 时刻的观测值, H 为隐藏状态数量, M 为观测符号数量。

为确定最优隐藏状态数量 H ,采用贝叶斯信息准则(Bayesian information criterion, BIC)进行模型选择,如式(16)所示。

$$\text{BIC} = -2\log P(O | \lambda) + k\log(L) \quad (16)$$

其中, O 为观测序列, λ 为 HMM 模型参数, k 为模型参数总数, L 为观测序列长度。BIC 准则同时考虑模型拟合优度(对数似然值 $\log P(O | \lambda)$)与模型复杂度(参数数量 k),通过惩罚项 $k\log(L)$ 避免过拟合。

最优状态数 H^* 由最小化 BIC 值确定,如式(17)所示。

$$H^* = \underset{H}{\text{argmin}} \text{BIC}(H) \quad (17)$$

BS 方法通过迭代二分序列并最小化段内代价以定位微小变化,最优分割点 t^* 如式(18)所示。

$$t^* = \underset{t_i < t < t_{i+1}}{\text{argmin}} [c(y[t_i:t]) + c(y[t:t_{i+1}])] \quad (18)$$

其中, $c(\cdot)$ 为子段代价^[32](采用高斯核代价函数), $y[\cdot]$ 为时间序列。

DA 方法通过计算变化率识别加速退化^[33],退化角 γ 如式(19)所示。

$$\gamma = \arctan\left(\frac{y_{t_{k+h}} - y_{t_k}}{h}\right), h > 0 \quad (19)$$

其中, y_{t_k} 表示 t_k 时刻的退化状态, h 为区间长度。

EWMA 方法通过递归加权平均快速响应突变^[34] 如式(20)所示。

$$EWMA_t = \delta y_t + (1 - \delta) EWMA_{t-1} \quad (20)$$

自适应多阶段变化点检测整体算法流程如算法1所示。

算法1: 自适应多阶段变化点检测

输入: 轴承信号数据集 $V = \{v_1, v_2, \dots, v_n\}$, 其中 v_i 表示第 i 个时间点的信号。

输出: 变化点集合 C 。

- 1: HMM 估计获取最优退化阶段数 K^* , 变化点数为 $K^* - 1$ 。
- 2: 定义检测方法集 $M = \{\text{BS}, \text{DA}, \text{EWMA}\}$ 。
- 3: 初始化变化点集合 $C = \emptyset$ 。
- 4: 对 $i = 1$ 到 $K^* - 1$:
 - (a) 令 $MSE_{\min} = \infty$;
 - (b) 对每个 $m \in M$: 求候选点 c_m , 计算退化阶段内均方误差 MSE_m ;
 - (c) 若 $MSE_m < MSE_{\min}$, 则更新 $MSE_{\min}$ 与对应变化点及检测方法 (c^*, m^*) ;
 - (d) 将 (c^*, m^*) 加入集合 C , 并按时间索引对 C 升序;
 - (e) 更新数据集 $V = V[c^* + 1:]$ 进入下一阶段。
- 5: 返回变化点集合 C 。

2.2 基于稀疏高斯过程回归的多阶段 RUL 预测

在识别所有变化点后, 构建自适应多阶段稀疏高斯过程回归模型进行剩余使用寿命预测^[21]。设训练集 $D = \{x_i, y_i\}_{i=1}^n$, 其中, $\mathbf{X} = \{x_i\}_{i=1}^n$ 为输入矩阵, $\mathbf{y} = \{y_i\}_{i=1}^n$ 为对应的输出目标变量, n 为样本数量。带噪声 GPR 模型如式(21)所示。

$$\mathbf{y} = f(\mathbf{X}) + \boldsymbol{\varepsilon} \quad (21)$$

其中, $\boldsymbol{\varepsilon} \sim N(0, \sigma_n^2 \mathbf{I})$ 为高斯白噪声。

其先验如式(22)所示。

$$\mathbf{y} \sim N(\boldsymbol{\mu}(\mathbf{x}), k(\mathbf{x}, \mathbf{x}') + \sigma_n^2 \mathbf{I}) \quad (22)$$

其中, $\boldsymbol{\mu}(\mathbf{x})$ 为均值函数, $k(\mathbf{x}, \mathbf{x}')$ 为协方差函数。

超参数向量通过如式(23)、式(24)所示的最小化负对数边际似然求得, 即:

$$\hat{\boldsymbol{\theta}} = \arg\min_{\boldsymbol{\theta}} [-\log P(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta})] - \quad (23)$$

$$\log P(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) = \frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})^T (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} (\mathbf{y} - \boldsymbol{\mu}) + \quad (24)$$

其中, $\boldsymbol{\theta}$ 为模型参数向量, 包括协方差函数参数和噪声方差等。 $\boldsymbol{\mu} = \boldsymbol{\mu}(\mathbf{X})$ 为均值函数, $\mathbf{K} = k(\mathbf{X}, \mathbf{X})$ 为协方差矩阵。

SGPR 在 GPR 的基础上通过引入诱导点集 $\mathbf{Z}$ 降低计

算量^[22]。采用完全独立训练条件 (fully independent training conditional, FITC) 近似, 其预测均值与协方差如式(25)、(26)所示。

$$\boldsymbol{\mu}_* = \boldsymbol{\mu}(\mathbf{Z}) + \mathbf{Q}_{\mathbf{Z}\mathbf{X}} \tilde{\mathbf{K}}_{\mathbf{X}\mathbf{X}}^{-1} (\mathbf{y} - \boldsymbol{\mu}(\mathbf{Z})) \quad (25)$$

$$\mathbf{cov}_* = \mathbf{K}_{\mathbf{Z}\mathbf{Z}} - \mathbf{K}_{\mathbf{Z}\mathbf{X}} \tilde{\mathbf{K}}_{\mathbf{X}\mathbf{X}}^{-1} \mathbf{K}_{\mathbf{X}\mathbf{Z}} \quad (26)$$

其中, 定义任意下标 a, b, c 的 $\mathbf{Q}_{ac} = \mathbf{K}_{ab} \mathbf{K}_{bb}^{-1} \mathbf{K}_{bc}$ 。 $\tilde{\mathbf{K}}_{\mathbf{X}\mathbf{X}} = \mathbf{Q}_{\mathbf{X}\mathbf{X}} + \text{diag}(\mathbf{K}_{\mathbf{X}\mathbf{X}} - \mathbf{Q}_{\mathbf{X}\mathbf{X}})$ 。 $\text{diag}(\cdot)$ 为对角矩阵。

每个退化阶段使用独立的 SGPR 模型进行建模, 整体退化过程如式(27)所示。

$$\mathbf{y} = \begin{cases} \text{SGP}(\boldsymbol{\mu}(t_i), \mathbf{K}_1), & \rho_1 \leq t_i < \rho_2 \\ \text{SGP}(\boldsymbol{\mu}(t_i), \mathbf{K}_2), & \rho_2 \leq t_i < \rho_3 \\ \vdots \\ \text{SGP}(\boldsymbol{\mu}(t_i), \mathbf{K}_M), & t_i \geq \rho_{M+1} \end{cases} \quad (27)$$

其中, $\rho_j (j = 1, 2, \dots, M+1)$ 为第 j 个变化点, $\mathbf{K}_i (i = 1, 2, \dots, M+1)$ 为第 i 阶段协方差函数, $\boldsymbol{\mu}(t_i)$ 表示均值函数。

选用线性均值函数如式(28)所示。

$$\boldsymbol{\mu}(t_i) = \mathbf{e}_1 t_i + \mathbf{e}_2 \quad (28)$$

其中, $\mathbf{e}_1$ 和 $\mathbf{e}_2$ 为线性函数参数。

协方差函数随阶段自适应选择: 早期平滑阶段采用平方指数 (squared exponential, SE) 刻画小幅平稳波动, 如式(29)所示。

$$\mathbf{K}_{\text{SE}} = \delta_s^2 \exp\left(-\frac{(t-t')^T(t-t')}{2q_1^2}\right) \quad (29)$$

其中, δ_s^2 为信号方差, q_1 为长度尺度。

中后期非平滑阶段采用马特恩 (Matérn) 核以适配更尖锐的波动与不连续导数, 如式(30)所示。

$$\mathbf{K}_{\text{Matérn}} = \delta_M^2 \left(1 + \frac{\sqrt{2\nu}(t-t')^T(t-t')}{q_2}\right) \times \exp\left(-\frac{\sqrt{2\nu}(t-t')^T(t-t')}{q_2^2}\right) \quad (30)$$

其中, δ_M^2 为信号方差, ν 为平滑度参数, ν 越大, 函数越平滑, 值越小, 越能捕捉剧烈变化和尖锐波动, q_2 为长度尺度。随着退化过程中波动特性的变化, 可采用 Matérn 5/2 ($\nu = 5/2$)、Matérn 3/2 ($\nu = 3/2$) 逐步降低至更小的 ν 值, 以逐步适应从平滑到剧烈波动的退化特性。

采用均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 作为模型评价指标^[35], 如式(31)、(32)所示。

$$\text{RMSE} = \sqrt{\frac{1}{n_r} \sum_{i=1}^{n_r} (D_i - \hat{D}_i)^2} \quad (31)$$

$$\text{MAE} = \frac{1}{n_r} \sum_{i=1}^{n_r} |D_i - \hat{D}_i| \quad (32)$$

其中, D_i 为第 i 个点的实际值, $\hat{D}_i$ 为对应的预测值, n_r 为预测点数量。

3 实验验证

3.1 实验数据与工况描述

为验证所提虚拟健康指标构建与多阶段稀疏高斯过程回归预测模型的有效性和创新性,在同一实验台上通过设置不同转速、负载与工作周期,采集了 3 组在频繁启停循环工况下、6007 型深沟球轴承的全寿命振动数据。实验台如图 3 所示,轴承关键参数如表 2 所示,3 组实验配置与数据规模如表 3 所示。每组数据均覆盖从健康到完全失效的全过程,完整记录了频繁启停循环下的退化轨迹。



图 3 实验台 1:轴承故障实验台

Fig. 3 Experimental table 1: Faulty bearing test rig

表 2 实验台 1:深沟球轴承 6007 工作参数

Table 2 Experimental table 1: Operating parameters of deep groove ball bearing 6007

实验轴承参数	数值	实验轴承参数	数值
外圈直径	62 mm	内圈直径	35 mm
宽度	14 mm	滚子直径	7.92 mm
滚子个数	17	接触角	0°
单文件采样点数	38 400	采样频率	51.2 kHz

表 3 3 组实验数据说明

Table 3 Description of three experimental datasets

组别	转速/rpm	负载/N	工作周期/天	采样文件数
A	7 200	8 000	2	427
B	7 800	6 000	6	2 992
C	7 800	6 000	11	7 542

3.2 虚拟健康指标构建及其性能分析

采用所提 SA-PSO-STL 方法构建 VHI:先由 SA-PSO 在 31 个初始特征中筛选退化敏感特征(优化目标综合考虑单调性、趋势性、鲁棒性),随后以 PCA 融合得到初始健康序列,最终通过 STL 剥离周期性工况波动与随机噪声,提取表征退化趋势的 VHI。

图 4~9 与表 4~6 共同展示了在数据集 A、B、C 上不同方法构建的健康指标对比结果。为验证所提方法有效性,对比方法包括传统均方根(root mean square, RMS)指

标、全特征 PCA 融合,以及分出所提完整框架的关键步骤,即 SA-PSO 特征筛选+PCA 融合与全特征 PCA 融合+STL 趋势提取,用以验证将两者结合的完整流程的必要性与优越性。其中,RMS 指标作为工业界振动分析的基础基准,为性能评估提供参考原点^[5]。为验证所提方法创新性,引入 3 种具有代表性的深度学习模型作为基准:一维卷积神经网络(1-dimensional convolutional neural network, 1D-CNN)^[36]、LSTM^[8],时序卷积网络(temporal convolutional network, TCN)^[37],检验所提方法在频繁启停循环工况时是否优于当前主流数据驱动方法。




图 4 A 组数据集:传统、分布方法与所提模型构建虚拟指标

Fig. 4 Dataset A: Construction of virtual indicators by the traditional, distributional Methods and the proposed model




图 5 A 组数据集:深度学习与所提模型构建虚拟指标

Fig. 5 Dataset A: Construction of virtual indicators by the deep learning and the proposed model




图 6 B 组数据集:传统、分布方法与所提模型构建虚拟指标

Fig. 6 Dataset B: Construction of virtual indicators by the traditional, distributional methods and the proposed model




图 7 B 组数据集:深度学习与所提模型构建虚拟指标对比
Fig. 7 Dataset B: Construction of virtual indicators by the deep learning and the proposed model




图 8 C 组数据集:传统、分布方法与所提模型构建虚拟指标
Fig. 8 Dataset C: Construction of virtual indicators by the traditional, distributional methods and the proposed model




图 9 C 组数据集:深度学习与所提模型构建虚拟指标
Fig. 9 Dataset C: Construction of virtual indicators by the deep learning and the proposed model

图 4~9 可视化退化曲线可见,所提方法得到 VHI 有效剥离频繁启停引入的周期波动与随机噪声,呈现与持续不变工况下相似的由慢到快且更单调、更平滑的退化趋势^[6]。相比之下,PCA 融合及 PCA 融合+STL 趋势提取因未经特征筛选,其构建的指标出现相反单调趋势;RMS 与 SA-PSO 特征筛选+PCA 融合未能有效剥离周期性波动与噪声,导致曲线波动剧烈、单调性差;而 1D-CNN、LSTM、TCN 趋势方向正确,但输出因噪声干扰严重,存在明显局部非单调波动。

对应的定量评价如表 4~6 所示,SA-PSO-STL 在 3 组数据上均取得最高的单调性、趋势性、鲁棒性及综合评分,显著优于其他对比方法。

表 4 A 组数据集:不同虚拟指标构建方法综合评分对比
Table 4 Dataset A: Comprehensive scores comparison of different virtual index construction methods

构建方法	单调性	趋势性	鲁棒性	综合评分
RMS 指标	0.909 8	0.909 6	0.806 8	0.908 8
PCA	-0.899 1	0.909 2	0.572 0	0.303 8
SA-PSO+PCA	0.917 3	0.915 3	0.600 4	0.913 1
PCA+STL	-0.943 0	0.945 8	0.794 9	0.315 3
1D-CNN	0.503 3	0.605 4	0.861 9	0.549 4
LSTM	0.713 0	0.742 7	0.807 3	0.726 3
TCN	0.699 9	0.712 9	0.827 0	0.706 7
所提模型	0.970 4	0.949 9	0.814 5	0.955 5

表 5 B 组数据集:不同虚拟指标构建方法综合评分对比
Table 5 Dataset B: Comprehensive scores comparison of different virtual index construction methods

构建方法	单调性	趋势性	鲁棒性	综合评分
RMS 指标	0.598 2	0.578 6	0.845 4	0.593 1
PCA	0.598 2	0.578 6	0.559 5	0.589 7
SA-PSO+PCA	-0.734 1	0.752 2	0.680 3	-0.108 7
PCA+STL	-0.750 1	0.865 2	0.966 2	-0.068 3
1D-CNN	0.285 5	0.599 9	0.921 2	0.421 8
LSTM	0.739 5	0.778 7	0.860 5	0.757 0
TCN	0.713 5	0.691 4	0.904 0	0.706 7
所提模型	0.956 5	0.970 1	0.969 0	0.962 2

表 6 C 组数据集:不同虚拟指标构建方法综合评分对比
Table 6 Dataset C: Comprehensive scores comparison of different virtual index construction methods

构建方法	单调性	趋势性	鲁棒性	综合评分
RMS 指标	0.596 6	0.593 3	0.824 8	0.598 3
PCA	0.596 6	0.593 3	0.516 4	0.594 3
SA-PSO+PCA	-0.274 3	0.291 5	0.563 8	-0.055 2
PCA+STL	-0.962 1	0.954 3	0.985 8	-0.231 7
1D-CNN	0.496 3	0.670 1	0.942 8	0.566 0
LSTM	0.703 0	0.739 0	0.861 3	0.718 3
TCN	0.692 2	0.722 3	0.959 6	0.706 8
所提模型	0.998 5	0.973 6	0.985 3	0.989 2

3.3 变点检测与 RUL 预测结果及对比分析

基于上述获得 VHI,在数据集 A、B、C 的频繁启停循环工况全寿命数据上采用自适应多阶段预测模型。首先利用 BIC 准则选择最优隐藏状态数,以确定退化阶段数量,变化点数量结果如图 10~12 所示,变化点检测结果如表 7~9 所示。




图 10 A 组数据集:最优状态数选择

Fig. 10 Dataset A: Optimal state number selection




图 11 B 组数据集:最优状态数选择

Fig. 11 Dataset B: Optimal state number selection




图 12 C 组数据集:最优状态数选择

Fig. 12 Dataset C: Optimal state number selection

表 7 A 组数据集:自适应变化点检测结果

Table 7 Dataset A: Adaptive change-point detection results

检测方法	变化点 1	MSE_1	变化点 2	MSE_2	变化点 3	MSE_3
BS	175	0.003	296	0.010	378	0.008
DA	179	0.004	287	0.007	375	0.007
EWMA	186	0.006	374	0.050	381	0.009

表 8 B 组数据集:自适应变化点检测结果

Table 8 Dataset B: Adaptive change-point detection results

检测方法	变化点 1	MSE_1
BS	995	1.781×10^{-4}
DA	981	1.588×10^{-4}
EWMA	996	1.796×10^{-4}

表 9 C 组数据集:自适应变化点检测结果

Table 9 Dataset C: Adaptive change-point detection results

检测方法	变化点 1	MSE_1	变化点 2	MSE_2
BS	2 395	4.940×10^{-5}	3 641	1.989×10^{-4}
DA	3 607	3.000×10^{-4}	3 669	2.163×10^{-4}
EWMA	1 971	2.815×10^{-4}	3 621	1.882×10^{-4}

结果表明,所提方法构建的虚拟指标能有效进行自适应多阶段变化点检测和 RUL 预测。A 组数据集被划分为正常、缓慢退化、中期退化和加速退化 4 个阶段,各退化阶段自适应选择的最优变点检测方法依次为 BS-DA-DA,对应变点(样本序号)为 175、287 和 375。B 组数据集被划分为正常、加速退化 2 个阶段,自适应选择变点检测方法为 BS,对应变点(样本序号)为 995。C 组数据集被划分为正常、缓慢退化、加速退化 3 个阶段,各退化阶段自适应选择最优变点检测方法依次为 EWMA-EWMA,对应变点(样本序号)为 1 971 和 3 621。

为评估轴承 RUL 预测性能,采用分阶段的训练/测试划分:每一阶段的训练仅使用该阶段内的真实观测,避免将前一阶段的预测值作为后一阶段的训练输入。在识别到的变化点处重置模型,分别训练多阶段 SGPR。模型有 4 个关键超参数,即均值函数的线性系数 e_1 与常数项 e_2 ;协方差函数的特征长度尺度 δ 与信号方差 q 。超参数分两步优化:首先在预设的参数范围 $[-10, 10]$ 内对这 4 个参数采用步长为 1 的网格搜索,得到初步最优整数组合,再以此组合为中心在其 ± 0.5 邻域内以步长 0.1 进行精细搜索,从而获得一位小数精度的初始参数组合。随后,以此初始参数组合为起点,以最小化负对数边际似然为目标梯度优化超参数 θ ,并依据验证集的 RMSE 和 MAE 作为模型评价指标确定最优超参数组合。

诱导点 Z 为 $1 \sim 20^{[34]}$ 的等间隔分布。3 组数据的初始参数和优化参数为:

1) A 组数据:缓慢退化阶段:初始参数: $\{e_1 = 0.3, e_2 = 1.4, \delta_s = 4.2, q_1 = 1.3\}$, 优化参数: $\hat{\theta} = \{0.003, 0, 4.021, -61.686\}$ 。中期退化阶段:初始参数: $\{e_1 = 3.1, e_2 = 9.1, \delta_M = 3.6, q_2 = -0.4\}$, 优化参数: $\hat{\theta} = \{0.005, -1.288, 3.6, -1.371\}$ 。加速退化阶段:初始参数: $\{e_1 = 10.1, e_2 = 7.4, \delta_M = 7.5, q_2 = 7.3\}$, 优化参数: $\hat{\theta} = \{0.012, 7.394, 11.221, 3.227\}$ 。

2) B 组数据:加速退化阶段:初始参数: $\{e_1 = 8.2, e_2 = 8.9, \delta_s = 8.2, q_1 = 0.6\}$, 优化参数: $\hat{\theta} = \{-0.002, 8.900, 8.759, 1.510\}$ 。

3) C 组数据:缓慢退化阶段:初始参数: $\{e_1 = 9, e_2 = 5, \delta_s = 9, q_1 = 8\}$, 优化参数: $\hat{\theta} = \{-1.630 \times 10^{-4}, 4.975, 9.388, -0.364\}$ 。加速退化阶段:初始参数: $\{e_1 = 0.6, e_2 = 8.3, \delta_M = 8.9, q_2 = 5.8\}$, 优化参数: $\hat{\theta} = \{4.610 \times 10^{-5}, 8.300, 19.876, -0.749\}$ 。

图 13~15 为 3 组数据集的 RUL 预测结果,图中横轴为样本序号,纵轴为使用所提方法构建的虚拟健康指标值,实线代表所提方法预测的退化趋势,虚线代表真实退化趋势,阴影代表 95% 置信区间。可以观察到,在所有退化阶段,预测的退化趋势与实际的退化趋势基本吻合,表明在采用所提方法后,轴承退化趋势被基于 SGPR 的自适应多阶段 RUL 预测有效捕获。所提方法构建的 VHI 的预测曲线能够平滑、紧密地跟踪真实退化轨迹,尤其是在退化中后期,进入快速退化阶段时,预测曲线能够准确捕捉趋势的转折与加速,说明前期构建的 VHI 提供了清晰的退化信号,为后续预测奠定可靠基础。




图 13 A 组数据集:RUL 预测结果

Fig. 13 Dataset A: RUL prediction results

对 A、B、C 3 组频繁启停循环工况数据,分别使用所提方法构建的虚拟健康指标、以及基于不同健康指标




图 14 B 组数据集:RUL 预测结果

Fig. 14 Dataset B: RUL prediction results




图 15 C 组数据集:RUL 预测结果

Fig. 15 Dataset C: RUL prediction results

(RMS 指标、PCA 融合、SA-PSO + PCA、PCA + STL、1D-CNN、LSTM、TCN) 进行自适应多阶段轴承剩余使用寿命预测。所有方法均采用第 2.2 节所述的多阶段预测框架,以比较不同健康指标对预测性能的影响。表 10~12 表示 A、B、C 这 3 组数据的预测结果,针对不同方法,表中列出其变化点数量、各阶段采用的变化点检测方法组合及预测评估。结果表明,所提方法结合特征优选与趋势提取的优势,在 3 组数据上均达到最高预测精度,其 RMSE 和 MAE 都低于其他对比方法。传统方法(RMS 指标、PCA 融合)及分步方法(SA-PSO + PCA、PCA + STL)因所构建健康指标存在波动干扰或未经特征筛选造成趋势方向相反,导致 RUL 预测精度有限;1D-CNN、LSTM、TCN 虽能捕捉退化趋势,但周期性波动干扰未解决导致较大预测误差。相比之下,所提方法构建的 VHI 为预测模型提供了高质量输入,实现最优预测性能。这充分验证所提出方法构建的 VHI 在消除周期性干扰、恢复单调退化以及增强特征-退化关联方面的有效性和创新性,从而解决频繁启停循环工况下的轴承 RUL 预测。

表 10 A 组数据集;RUL 对比实验结果

Table 10 Dataset A;The comparison experiment results of RUL

构建方法	变化点 数量	变化点检 测方法	核函数	RMSE	MAE
RMS 指标	1	DA	SE	0.278	0.199
PCA	1	DA	SE	0.869	0.753
SA-PSO+PCA	2	DA-DA	SE-Matérn5/2	0.790	0.650
PCA+STL	2	BS-DA	SE-Matérn5/2	0.108	0.084
1D-CNN	1	BS	SE	0.497	0.482
LSTM	2	EWMA-BS	SE-Matérn5/2	0.453	0.300
TCN	1	BS	SE	0.478	0.451
所提模型	3	BS-DA-DA	SE-Matérn5/2 -Matérn3/2	0.106	0.047

表 11 B 组数据集;RUL 对比实验结果

Table 11 Dataset B; The comparison experiment results
of RUL

构建方法	变化点 数量	变化点检 测方法	核函数	RMSE	MAE
RMS 指标	2	EWMA-DA	SE-Matérn5/2	3.693	3.542
PCA	2	DA-EWMA	SE-Matérn5/2	4.309	4.025
SA-PSO+PCA	2	DA-DA	SE-Matérn5/2	3.367	3.018
PCA+STL	1	BS	SE	0.187	0.185
1D-CNN	2	BS-EWMA	SE-Matérn5/2	8.516	8.382
LSTM	2	EWMA-BS	SE-Matérn5/2	5.634	3.481
TCN	2	BS-BS	SE-Matérn5/2	6.267	4.386
所提模型	1	BS	SE	0.014	0.012

表 12 C 组数据集;RUL 对比实验结果

Table 12 Dataset C; The comparison experiment
results of RUL

构建方法	变化点 数量	变化点检 测方法	核函数	RMSE	MAE
RMS 指标	3	DA-BS-DA	SE-Matérn5/ 2-Matérn3/2	0.094	0.074
PCA	3	DA-BS-DA	SE-Matérn5/ 2-Matérn3/2	0.096	0.075
SA-PSO+PCA	3	DA-EWMA- BS	SE-Matérn5/ 2-Matérn3/2	0.233	0.177
PCA+STL	2	DA-DA	SE-Matérn5/2	0.015	0.014
1D-CNN	2	EWMA- EWMA	SE-Matérn5/2	1479	94
LSTM	1	BS	SE	1.022	0.985
TCN	2	BS-EWMA	SE-Matérn5/2	2374	241
所提模型	2	EWMA- EWMA	SE-Matérn5/2	0.002	0.002

4 结 论

本研究面向频繁启停循环工况下滚动轴承退化建模难题,提出了基于 SA-PSO-STL 的虚拟健康指标构建与 SGPR 驱动的自适应多阶段 RUL 预测方法。通过 SA-PSO 算法筛选敏感退化特征,并结合 STL 分解剥离周期波动,构建出表征性能退化的清晰指标。在此基础上,采用稀疏高斯过程回归实现自适应多阶段 RUL 预测。3 组频繁启停循环工况的轴承全寿命实验验证表明,所提方法显著提升了健康指标质量与寿命预测精度,其构建的 VHI 在 A、B、C 3 组数据上的综合评分分别达到 0.955 5、0.962 2、0.989 2, RUL 预测在相应数据上的 RMSE 与 MAE 分别低至 0.106、0.047、0.014 和 0.012、0.002、0.002,各项性能均显著优于所有对比方法。未来研究将致力于优化算法计算效率,进一步优化 SA-PSO 特征筛选及 STL 分解过程的计算速度,减少因数据增长和模型复杂化带来的计算负担,提升工程实用性。

参考文献

[1] WANG D, PENG ZH K, XI L F. Theoretical and experimental investigations on spectral Lp/Lq norm ratio and spectral gini index for rotating machine health monitoring [J]. IEEE Transactions on Automation Science and Engineering, 2020, 18(3):1074-1086.

[2] 武宏波,王思彤. 考虑间歇工作模式的电子式电能表可靠性预计[J]. 华北电力技术, 2011(9):8-12.

WU H B, WANG S T. Electronic electricity meter reliability prediction considering components' intermittent operation state [J]. North China Electric Power Technology, 2011(9):8-12.

[3] 王福民. 基于监测数据的汽轮机汽缸结构剩余寿命预测[D]. 大连:大连理工大学, 2020.

WANG F M. Prediction of remaining life of steam turbine cylinder structure based on monitoring data[D]. Dalian: Dalian University of Technology, 2020.

[4] 张青雷,黄魏平,陈堰芳. 周向均布拉杆转子低周疲劳寿命研究[J]. 机械设计与制造, 2016(1):238-242.

ZHANG Q L, HUANG W P, CHEN Y F. Research on the fatigue life of circumferential distributed rod fastening rotor[J]. Machinery Design & Manufacture, 2016(1): 238-242.

[5] 王丽媛. 300 MW 自然循环锅炉汽包寿命的预测方法[D]. 吉林:东北电力大学, 2007.

WANG L Y. Prediction method for drum life of a 300 MW natural circulation boiler[D]. Jilin: Northeast Electric

- Power University, 2007.
- [6] 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.
- [7] WU H, LI J M, ZHANG Q Y, et al. Intelligent fault diagnosis of rolling bearings under varying operating conditions based on domain-adversarial neural network and attention mechanism[J]. ISA Transactions, 2022, 130:477-489.
- [8] HUANG T, ZHANG Q, TANG X AN, et al. A novel fault diagnosis method based on CNN and LSTM and its application in fault diagnosis for complex systems[J]. Artificial Intelligence Review, 2022, 55(2): 1289-1315.
- [9] 乔卉卉,赵二贤,郝如江,等. 基于注意力机制与多源信息融合的变工况轴承故障诊断[J]. 仪器仪表学报, 2024, 45(9):120-130.
QIAO H H, ZHAO ER X, HAO R J, et al. Attention mechanism and multi-source information fusion-based method for bearing fault diagnosis under variable operating conditions[J]. Chinese Journal of Scientific Instrument, 2024, 45(9):120-130.
- [10] DJEZIRI M A, BENMOUSSA S, BENBOUZID M E H. Data-driven approach augmented in simulation for robust fault prognosis[J]. Engineering Applications of Artificial Intelligence, 2019, 86: 154-164.
- [11] 牛勇,李华鹏,刘阳惠,等. 超高维数据特征筛选方法综述[J]. 应用概率统计, 2021, 37(1):69-110.
NIU Y, LI H P, LIU Y H, et al. Overview of feature screening methods for ultrahigh dimensional data[J]. Chinese Journal of Applied Probability and Statistics, 2021, 37(1): 69-110.
- [12] GUO L, LI N P, JIA F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98-109.
- [13] 王久健,杨绍普,刘永强,等. 一种基于空间卷积长短时记忆神经网络的轴承剩余寿命预测方法[J]. 机械工程学报, 2021, 57(21):88-95.
WANG J J, YANG SH P, LIU Y Q, et al. A method of bearing remaining useful life estimation based on convolutional long short-term memory neural network[J]. Journal of Mechanical Engineering, 2021, 57(21): 88-95.
- [14] HONG SH, ZHOU ZH, ZIO E, et al. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method[J]. Digital Signal Processing, 2014, 27:159-166.
- [15] ZHANG Y CH, SUN J, LI J Y, et al. Quantitative analysis of cadmium content in tomato leaves based on hyperspectral image and feature selection[J]. Applied Engineering in Agriculture, 2018, 34(5):789-798.
- [16] CHEN Y X, CHEN L, HUANG CH, et al. A dynamic tire model based on HPSO-SVM[J]. International Journal of Agricultural and Biological Engineering, 2019, 12(2): 36-41.
- [17] 陈彦铭,游为. 基于模拟退火粒子群算法优化 BP 神经网络的 GNSS 高程异常拟合[J]. 测绘与空间地理信息, 2025, 48(5):16-19.
CHEN Y M, YOU W. GNSS height anomaly fitting based on simulated annealing and particle swarm optimization BP neural network[J]. Geomatics & Spatial Information Technology, 2025, 48(5):16-19.
- [18] 陈多. 基于时序分解的交通客流预测研究综述[J]. 中国储运, 2025(8):88-89.
CHEN D. Review of traffic passenger flow prediction research based on time series decomposition[J]. China Storage & Transport, 2025(8):88-89.
- [19] 王爽,宋秋昱,张驰,等. 高效带宽傅里叶分解及其轴承故障诊断应用[J]. 噪声与振动控制, 2024, 44(5):154-159.
WANG SH, SONG Q Y, ZHANG CH, et al. Efficient bandwidth Fourier decomposition and its application to bearing fault diagnosis[J]. Noise and Vibration Control, 2024, 44(5):154-159.
- [20] 曹丹阳,马金锋. 基于 STL 和 EMD 的时间序列预测算法研究[J]. 电子元器件与信息技术, 2021, 5(8):76-78.
CAO D Y, MA J F. Research on time series prediction algorithm based on STL and EMD[J]. Electronic Components and Information Technology, 2021, 5(8): 76-78.
- [21] 李晋国,周绍景,李红娇. GRU 结合 STL 分解的短期电量预测方法[J]. 上海电力大学学报, 2020, 36(5):415-420.
LI J G, ZHOU SH J, LI H J. A short-term electricity forecasting method based on GRU and STL decomposi-

- tion[J]. Journal of Shanghai University of Electric Power, 2020, 36(5):415-420.
- [22] 王晓燕,郎贺,王品,等. 基于 STL 分解的平均故障间隔时间组合预测[J]. 机床与液压, 2021, 49(17):196-200.
- WANG X Y, LANG H, WANG P, et al. Combined prediction of mean time between failures based on STL decomposition[J]. Machine Tool & Hydraulics, 2021, 49(17):196-200.
- [23] 李逸航,肖辉,易纯,等. 基于 STL 分解和 TPA 机制的光伏功率区间预测[J]. 太阳能学报, 2024, 45(12):22-29.
- LI Y H, XIAO H, YI CH, et al. Photovoltaic power interval prediction based on STL decomposition and TPA mechanism[J]. Acta Energaie Solaris Sinica, 2024, 45(12):22-29.
- [24] RASMUSSEN C E, WILLIAMS C K I. Gaussian processes for machine learning[M]. Cambridge: The MIT Press, 2005.
- [25] GU M H, FEI J J, SUN SH L. Online anomaly detection with sparse Gaussian processes [J]. Neurocomputing, 2020, 403:383-399.
- [26] 梅雨. 基于模拟退火粒子群算法的微电网优化调度[J]. 现代信息科技, 2025, 9(5):134-138.
- MEI Y. Optimal scheduling of microgrids based on simulated annealing particle swarm optimization algorithm[J]. Modern Information Technology, 2025, 9(5):134-138.
- [27] 武东超,葛飞,方圆,等. 基于有限元分析的 PCA-LSTM 模型预测 PC 梁桥长期性能[J]. 现代交通与冶金材料, 2026, 6(1):28-41.
- WU D CH, GE F, FANG Y, et al. PCA-LSTM model for long-term behavior prediction of prestressed concrete bridges via finite element simulations [J]. Modern Transportation and Metallurgical Materials, 2026, 6(1):28-41.
- [28] 郑心雨. 数据驱动的滚动轴承剩余寿命预测[D]. 镇江: 江苏大学, 2024.
- ZHENG X Y. Data driven rolling bearing remaining useful life prediction[D]. Zhenjiang: Jiangsu university, 2024.
- [29] ZHU Y X, TIAN D Z, YAN F. Effectiveness of entropy weight method in decision-making [J]. Mathematical Problems in Engineering, 2020, 2020:1-5.
- [30] ZHENG X Y, FAN W, CHEN CH, et al. Adaptive two-stage model for bearing remaining useful life prediction using Gaussian process regression with matched kernels[J]. IEEE Transactions on Reliability, 2024, 73(4):1958-1966.
- [31] 刘文溢,刘勤明,叶春明,等. 基于改进退化隐马尔可夫模型的设备健康诊断与寿命预测研究[J]. 计算机应用研究, 2021, 38(3):805-810.
- LIU W Y, LIU Q M, YE CH M, et al. Equipment health diagnostics and prognostics method based on improved degenerated HMM [J]. Application Research of Computers, 2021, 38(3):805-810.
- [32] SON J B, ZHANG Y L, SANKAVARAM C, et al. RUL prediction for individual units based on condition monitoring signals with a change point [J]. IEEE Transactions on Reliability, 2015, 64(1):182-196.
- [33] WANG ZH J, TA Y T, CAI W AN, et al. Research on a remaining useful life prediction method for degradation angle identification two-stage degradation process [J]. Mechanical Systems and Signal Processing, 2023, 184:109747.
- [34] HAWKINS D M, QIU P H. The changepoint model for statistical process control [J]. Journal of Quality Technology, 2003, 35(4):355-366.
- [35] 陈仁祥,张雁峰,徐向阳,等. 基于子空间域对抗判别网络的不同型号滚动轴承剩余寿命预测[J]. 仪器仪表学报, 2024, 45(3):119-127.
- CHEN R X, ZHANG Y F, XU X Y, et al. Remaining life prediction of different types of rolling bearings based on subspace domain adversarial discrimination network[J]. Chinese Journal of Scientific Instrument, 2024, 45(3):119-127.
- [36] 付文泓,胡志华,陶莉莉. 基于 1D-CNN 的消防水力系统状态监测与故障诊断[J]. 现代电子技术, 2025, 48(24):54-60.
- FU W H, HU ZH H, TAO L L. 1D-CNN-based condition monitoring and fault diagnosis of fire hydraulic system [J]. Modern Electronics Technique, 2025, 48(24):54-60.
- [37] 陈龙,魏勇,马建新,等. TCN-Transformer 组合模型的锂电池 SOC 估[J]. 重庆理工大学学报(自然科学), 2025, 39(11):241-247.
- CHEN L, WEI Y, MA J X, et al. TCN-Transformer combined model for State of Charge estimation of lithium-ion batteries [J]. Journal of Chongqing University of Technology (Natural Science), 2025, 39(11):241-247.

作者简介



高晓旭, 2023 年于杭州电子科技大学获得通信工程学士学位, 现在江苏大学攻读仪器科学与技术硕士学位, 主要研究方向为信号处理和机械故障诊断。

E-mail: gaoxiaoxu19081802@163.com


Gao Xiaoxu received her B. Sc. degree in Communication Engineering from Hangzhou Dianzi University in 2023. She is currently pursuing the master's degree in Instrument Science and Technology from Jiangsu University. Her main research interests include signal processing and machinery fault diagnosis.



樊薇(通信作者), 2012 年和 2015 年于苏州大学分别获学士和硕士学位, 2018 年于香港城市大学获博士学位。现为江苏大学机械工程学院教授。主要研究方向为信号处理和机械故障诊断。

E-mail: weifan@ujs.edu.cn

Fan Wei (Corresponding author) received her B. Sc. and M. Sc. degrees both from Soochow University in 2012 and 2015, respectively, and the Ph. D. degree from City University of Hong Kong in 2018. She is currently a professor with the School of Mechanical Engineering, Jiangsu University. Her research interests include signal processing and machinery fault diagnosis.



陈超, 2011 年和 2014 年于江苏大学分别获得学士和硕士学位, 2020 年于东南大学获博士学位, 现为江苏大学讲师、硕士生导师, 主要研究方向为信号处理、机械系统状态监测与智能故障诊断。

E-mail: chenchaoy@ujs.edu.cn

Chen Chao received his B. Sc. and M. Sc. degrees both from Jiangsu University in 2011 and 2014, respectively, and received his Ph. D. degree from Southeast University in 2020. He is currently a lecturer and M. Sc. supervisor in Jiangsu University. His main research interests include signal processing, machine condition monitoring and intelligent fault diagnosis.



陈龙, 1982 年于江苏工学院获学士学位, 2006 年于江苏大学获博士学位, 江苏大学汽车工程研究院教授。主要研究方向为机械故障诊断。

E-mail: chenlong@ujs.edu.cn

Chen Long received his B. Sc. degree from Jiangsu Institute of Technology in 1982, and M. Sc. degree from Jiangsu University in 2006. He is currently a professor at the Automotive Engineering Research Institute. His main research interests include machinery fault diagnosis.



朱忠奎, 1997 年和 2002 年于合肥工业大学分别获学士和硕士学位, 2004 年于中国科学技术大学获博士学位。现为苏州大学轨道交通学院教授。主要研究方向为旋转机械状态监测与故障诊断。

E-mail: zhuzhongkui@suda.edu.cn

Zhu Zhongkui received his B. Sc. and M. Sc. degrees both from Hefei University of Technology in 1997 and 2002, respectively, and his Ph. D. degree from University of Science and Technology of China in 2004. He is currently a professor with School of Rail Transportation, Soochow University. His main research interests include condition monitoring and fault diagnosis of rotating machinery.