

doi: 10.7690/bgzdh.2023.05.009

基于性能退化指标的轴承剩余寿命预测及其应用

高玉霞, 王向华, 王静远, 王介港

(山东科技大学电气与自动化工程学院, 山东 青岛 266590)

摘要: 为确保系统可用性和降低维修成本, 提出基于性能退化指标的轴承剩余使用寿命 (remaining useful life, RUL) 预测模型预测轴承的 RUL。通过局部均值分解 (local mean decomposition, LMD) 将轴承原始振动数据分解为若干积性函数 (PF) 分量, 并根据峰度准则选取有效的 PF 分量重构原始信号; 提取重构原始信号的时域退化特征量, 利用基于人工神经网络 (artificial neural network, ANN) 训练的注意力机制模型选择高质量特征; 引入 K_均值聚类算法与分段拟合获得健康的退化指标 (health degradation indicator, HI), 利用灰色回归模型 (grey regression model, GM) 评估轴承退化可信度范围, 并建立基于 HI 的粒子群优化最小二乘支持向量机模型 (particle swarm optimization least squares support vector machine, PSO_LSSVM) 预测轴承 RUL。实验结果表明, 该方法在预测可靠性上取得良好的效果。

关键词: 轴承; 特征选择; 健康退化指标; 退化状态评估

中图分类号: TP301.6 **文献标志码:** A

Based Performance Degradation Indicator RUL Prediction and Its Application in Bearing

Gao Yuxia, Wang Xianghua, Wang Jingyuan, Wang Jiegang

(College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: In order to ensure system availability and reduce maintenance cost, a bearing RUL (remaining useful life) prediction model based on performance degradation index is proposed to predict the RUL of bearings. The original vibration data is decomposed into several multiplicative functions (PFs) by local mean decomposition (LMD), and the effective PFs are selected to reconstruct the original signal according to the kurtosis criterion; Time domain degradation features of the reconstructed original signal are extracted, and high-quality features are selected by using an attention mechanism model based on artificial neural network (ANN) training; The K _ mean clustering algorithm and piecewise fitting were introduced to obtain the health degradation indicator (HI), and the grey regression model (GM) was used to evaluate the reliability range of bearing degradation. And the HI-PSO LS-SVM model (particle swarm optimization least squares support vector machine, PSO _ LSSVM) is established to predict the bearing RUL. The experimental results show that the method has achieved good results in the prediction of reliability.

Keywords: bearings; feature selection; health degradation indicator; degraded state assessment

0 引言

轴承是旋转机械的关键部件之一, 一旦发生故障可能会造成巨大的损失。若能精准预测其剩余使用寿命 (RUL), 不仅能提高生产效率, 还能减少维修时间^[1]; 因此, 有必要构建健康的退化指标, 以建立良好的 RUL 预测模型。

RUL 预测方法包括基于经验、模型和数据^[2]。相比前 2 种方法, 基于数据的方法可直接利用监测数据获得有用的退化信息^[3]。因轴承的退化状态极其复杂, 传统单一退化指标无法充分反映轴承的退化信息^[4-5], 所以提取时域特征量描述轴承的退化状态。另外, 针对在人工干预的情况下, 很难自适应

地衡量时域特征量中的重要特征这一问题, 笔者在前人的基础上^[6]提出了基于人工神经网络 (ANN) 训练的注意力机制模型, 对不同的特征量进行自动加权, 以获取重要的特征。在获得重要特征后, 另一个核心是如何获得健康的退化指标描述轴承的退化状态, 这也是面临的难点之一^[7]。轴承在运行过程中持续地承受着交变应力, 振动信号中会出现虚假波动。为解决上述问题, Yang 等^[8]利用 GM 模型来修复轴承运行过程中产生的虚假波动, 保证轴承退化指标的单调性。该方法只修复了肉眼可见的虚假波动。在实际生产中, 设备会经历运转-停机-再运转的过程, 可能在健康状态下也避免不了有微弱的

收稿日期: 2023-01-17; 修回日期: 2023-02-18

基金项目: 国家自然科学基金资助项目 (61973197; 61603222)

作者简介: 高玉霞 (1994—), 女, 山东人, 硕士, 从事滚动轴承的剩余寿命预测以及故障诊断研究。E-mail: gaoyuxia94@163.com。

波动, 若不能及时修复, 会影响到预测结果。Peng 等^[9]利用高斯混合模型(Gaussian mixture model, GMM)对重要特征进行聚类, 能够有效识别异常数据, 减少冗余; 但当 GMM 没有足够的点时, 估算协方差就会变得困难, 同时算法会发散, 除非人为地对协方差进行正则化才能避免这些问题。针对以上方法的不足, 笔者引入 K_均值聚类算法与分段拟合来获得健康的退化指标(HI)。通过 K_均值聚类算法识别离群点, 再利用分段拟合修复虚假波动, 使其符合轴承的退化规律。既能够提高轴承 RUL 预测的可靠性, 又保证了轴承退化指标的单调性。

在进行 RUL 预测之前, 需评估轴承退化可信度范围。Yan 等^[10]利用支持向量机(support vector machine, SVM)对退化趋势进行预测。王奉涛等^[11]提出基于改进的 Logistic 回归模型可靠性评估方法。以上方法都取得了良好的效果, 但也存在一定的问题: 它们都需调节重要参数, 若参数调节不好, 则会导致评估精度降低。为了克服该缺点, 笔者采用 GM 回归模型, 主要利用最小二乘法估计出模型参数, 以便评估轴承退化状态。最后, 建立基于 HI 的 PSO_LSSVM^[12]预测轴承 RUL。

综上所述, 提出基于性能退化指标的 RUL 预测模型。主要研究内容如下:

1) 针对在人工干预的情况下, 很难自适应地衡量时域特征量中的重要特征问题, 提出基于 ANN 训练的注意力机制模型, 对不同的特征量进行自动加权, 筛选出高质量特征。

2) 为了获得稳定的、健康的退化指标, 先计算出高质量特征的方差值, 再引入 K_均值聚类算法与分段拟合移除方差值中的离群点并修复其虚假波动。

3) 采用 GM 回归模型评估轴承退化可信度范围, 准确地区分出轴承在每个阶段的退化状态。

1 剩余寿命预测方法

该方法的整体框架包括数据预处理、构建健康退化指标和退化状态评估 3 部分。整个框架如图 1。

1.1 数据预处理

在标准局部均值分解(LMD)的分解过程中, 一般采用移动平均技术构造包络线; 但多次平滑后, 导致局部信号段过度平滑, 影响分解的准确度^[13]。笔者利用 3 次样条插值(cubic spline interpolat, CSI)代替移动平均技术, 并引入峰度准则^[14]选择有效的

PF 分量进行重构。其步骤如下:

Step 1: 从设备中采集轴承的原始振动数据。

Step 2: 局部极值序列求解仍按照标准 LMD 算法。

Step 3: 通过 CSI 计算得到极大值序列(Max_{vec})与极小值序列(Min_{vec})的上包络线($E_u(t)$)与下包络线($E_l(t)$)。

Step 4: 局部均值函数 $mm(t)$ 和局部包络估计函数 $aa(t)$ 由上包络线 $E_u(t)$ 和下包络线 $E_l(t)$ 计算得到。定义如下:

$$mm(t) = (E_u(t) + E_l(t)) / 2; \quad (1)$$

$$aa(t) = (|E_u(t) - E_l(t)|) / 2. \quad (2)$$

Step 5: 继续按照标准 LMD 算法的其他步骤, 对原始振动数据进行 PF 分解。

Step 6: 根据峰度准则选取有效的 PF 分量。如果多个 PF 分量满足要求, 将其叠加得到重构原始信号 $X_{New}(t)$ 。如果只有一个有效的 PF 分量, 则定义单个 PF 分量为重构原始信号 $X_{New}(t)$ 。

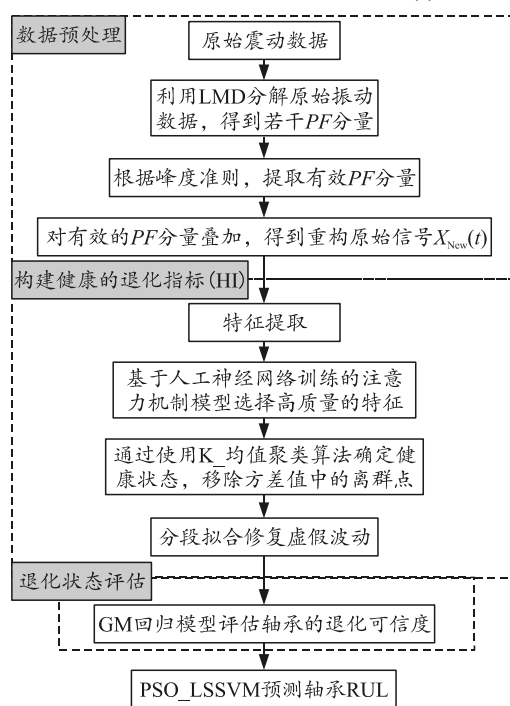


图 1 剩余寿命预测方法

1.2 构建健康的退化指标

健康退化指标的构建包括特征提取与选择、移除离群点与修复虚假波动 2 部分。

1.2.1 特征提取与选择

提取重构原始信号的时域特征量描述轴承的退化状态。时域特征集为 $T=[\text{最大值(Max)}, \text{最小值}(\text{Min})]$ 。

(Min), 峰值 (Peak), 峰峰值 (P2p), 平均值 (Mean), 绝对平均值 (Average Amplitude), 方根幅值 (Root Amplitude), 方差 (Var), 标准差 (Std), 均方根 (Rms), 峭度 (Kurtosis), 偏度 (Skewness)]. $T \in R^{N \times F}$, N 为样本个数, F 为特征量个数。

对于上述所提取的退化特征量, 利用 ANN 训练注意力机制模型, 实现不同特征量的自动加权。以时域特征集 T 为输入, 基于 ANN 训练的注意力机制模型主要由以下 4 个公式表示:

$$H = f(TW_1^T); \quad (3)$$

$$y = \text{soft max}(HW_2^T); \quad (4)$$

$$W = T \otimes y; \quad (5)$$

$$W_{\text{mean}}(i) = \frac{1}{N} \sum_{n=1}^N W_{ni}. \quad (6)$$

式中: $H \in R^{N \times 1}$ 为注意力权向量; $y \in R^{N \times F}$ 为归一化注意力权矩阵。将 T 与 y 逐项相乘, 生成新的加权矩阵 $W \in R^{N \times F}$, $W(i) = [W_{1i}, \dots, W_{Ni}]$, N 为总样本的个数, i 为特征的个数。最后, 利用式(6)对 W 取平均值, 得到平均加权向量 $W_{\text{mean}} \in R^{1 \times F}$ 。式(3)–(6)为 ANN 的前向传播。在反向传播中, $W_1 \in R^{1 \times F}$ 和 $W_2 \in R^{F \times 1}$ 分别通过梯度下降法更新。 $f(\bullet)$ 为 \tanh 函数。 W_{mean} 越大, 表示时域特征的退化能力就越强; 因此, 需根据特征的分布情况设置阈值, 判断是否为高质量特征。

1.2.2 移除离群点与修复虚假波动

经过一段时间的运行后, 轴承的振动信号会出现所谓的虚假波动。为使 RUL 预测更加准确, 有必要构建健康的退化指标。具体实现步骤如下:

- 1) 计算高质量特征的方差值。值得注意的是, 方差值能使虚假波动表现的更明显。
- 2) 根据 K _均值聚类算法得到散点的位置, 快速找到方差值中的离群点。
- 3) 利用分段拟合描述轴承的退化过程。在拟合前需找到退化阈值 D , 当退化指标小于 D 时, 退化指标为健康状态, 采用一次函数描述第一阶段; 当退化指标大于且等于 D 时, 退化指标会出现不同程度的损伤, 轴承退化趋势呈现单调性, 采用指数退化模型描述第 2 阶段。分段拟合模型定义如下:

$$\left. \begin{aligned} y &= KX + b & y < D \\ y &= Y + ae^{\beta X} & y \geq D \end{aligned} \right\}. \quad (7)$$

式中: K 、 b 、 a 和 β 由最小二乘计算, K 与 b 分别为稳定运行时的斜率与截距; Y 为早期故障的初始

值(退化阈值 D); a 控制拟合值的改变; β 控制指数的增长。

经过修复后的退化指标满足 3 个要求: 1) 健康状态下, 退化指标保持稳定; 2) 刚达到 D 时, 退化指标开始缓慢增加; 3) 在严重退化时, 退化指标呈现指数增长, 直到完全失效。

1.3 退化状态评估

在进行 RUL 预测之前, 需评估轴承退化可信度范围。将退化过程视为一个灰色系统, 利用已知系统推导退化指标的状态和发展趋势。GM 由单变量一阶微分方程组成, 其建立过程如下:

首先, 利用移除离群点的方差值 $X = [X(1), \dots, X(N)]$, 经过分段 3 次 Hermite 插值计算得到 $X^{(0)} = [X^{(0)}(1), \dots, X^{(0)}(N)]$ 。

然后求 $X^{(0)}$ 一次累加生成序列 $X^{(1)} = [X^{(1)}(1), \dots, X^{(1)}(N)]$ 。

式中: $X^{(1)}(k) = \sum_{i=1}^k X^{(0)}(i)$ ($k=1, 2, \dots, N$), X 为行向量; N 为总样本个数。

建立回归方程:

$$dX^{(1)}/dt + \delta X^{(1)} = \mu. \quad (8)$$

式中: δ 为发展系数; μ 为灰作用量。

式(8)的解为:

$$X^{(1)}(t) = [X^{(1)}(1) - \mu/\delta]e^{-\delta t} + \mu/\delta. \quad (9)$$

其离散解为:

$$X^{(1)}(k+1) = [X^{(1)}(1) - \mu/\delta]e^{-\delta k} + \mu/\delta. \quad (10)$$

对式(10)做累减处理, 得到 $X^{(0)}$ 的 GM 模型:

$$X^{(0)}(k+1) = X^{(0)}(k+1) - X^{(0)}(k). \quad (11)$$

值得注意的是, 利用移除离群点的方差值作为原始数列, 主要原因为: 1) 未移除离群点时会有太多波动; 2) 若采用分段拟合值又太过于平滑。这 2 个原因都有可能最终导致最终的评估结果不准确。

2 剩余寿命预测实验举例

通过实验验证所提方法的有效性, 具体实验流程如下:

1) 通过获得 XJTU-SY^[15]的轴承全寿命周期监测数据进行实验分析。

2) 如图 2 所示, 采用 LMD 方法将原始振动数据分解为若干 PF 分量, 根据峰度准则选取峰度值大于 3 的 PF 分量。最后, 选择 PF_4 作为有效分量, 得到重构原始信号 $X_{\text{New}}(t)$ 进行后续分析。

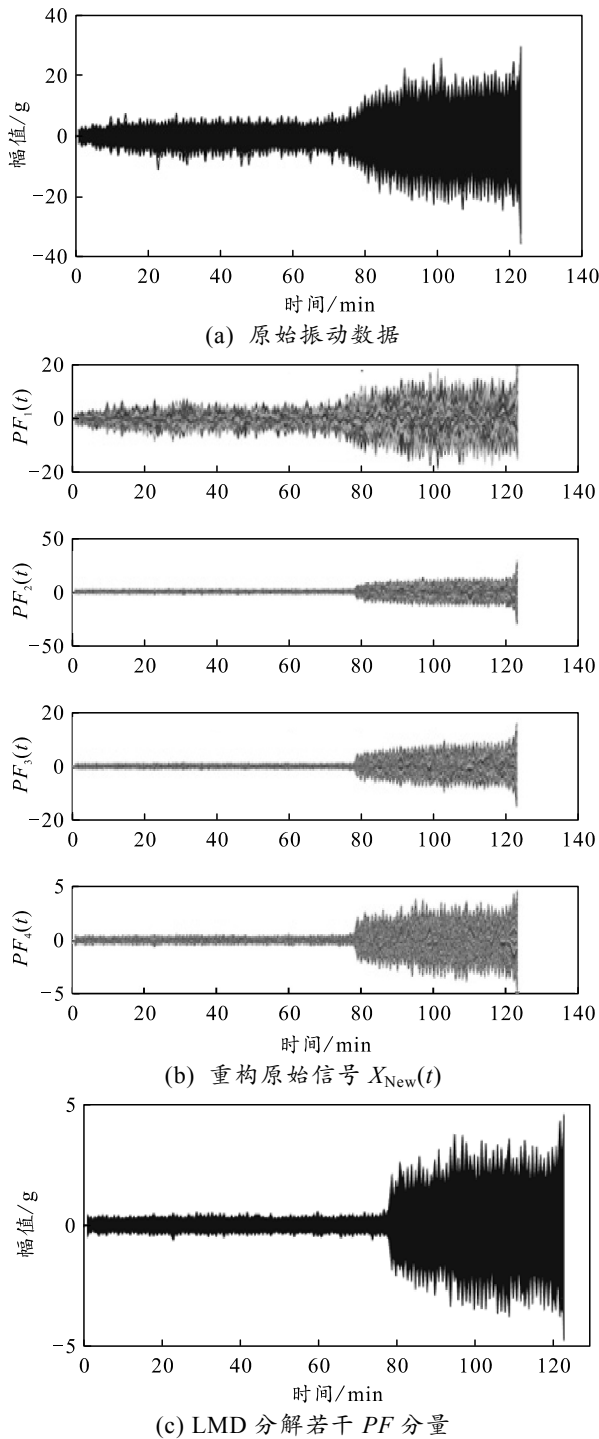


图 2 利用 LMD 重构原始信号流程

3) 提取重构原始信号 $X_{New}(t)$ 的 12 个时域退化特征量。为全面地评价轴承的退化状态，使用滑动平均滤波器进一步消除时域退化特征中的少量噪声，设置每个滑动窗口的长度为 20。

4) 对于经过滑动平均滤波后的 12 个退化特征，利用基于 ANN 训练的注意力机制模型，实现不同特征量的自动加权。如图 3 所示，中间特征量大约处于平齐状态，认为它们的退化能力几乎相同；

后面特征量的权值越来越大，退化能力也越来越强，所以设置阈值为 0.003 (由图 3 虚线表示)。当权值大于 0.003 时，说明该特征有利于 RUL 预测。另外，该模型并没有给特征量赋予固定的权值，特征量的权值可能在不同时刻有所不同，为此进行了多次训练，对多次训练累加求平均值。

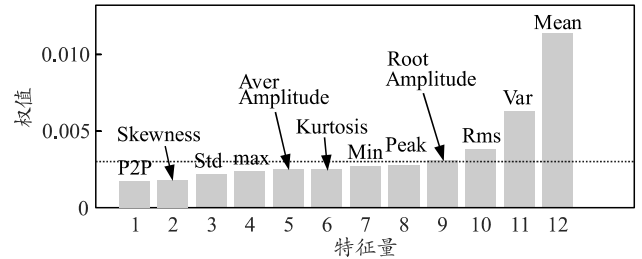


图 3 不同特征的平均注意权重

5) 经过一段时间的运行后，轴承的振动信号会出现虚假波动。为了避免 RUL 预测不准确，引入 K_均值聚类算法与分段拟合获得健康的退化指标。如图 4 所示，聚类结果与方差的波动密切相关。图中虚线仅为了清楚区分轴承正常状态与退化状态下聚类结果与方法波动的情况。




图 4 聚类结果与方差

根据肘部法则得到最优簇数为 5。由 K_均值得到散点的位置，共识别出 15 个离群点。随后，利用分段拟合修复退化过程中产生的虚假波动，采用梯度值得到退化阈值 D 为 0.004，根据式(7)得到拟合结果。如图 5 所示，拟合值无虚假波动，符合经修复后退化指标所满足的 3 个要求。




图 5 分段拟合结果

6) 在进行 RUL 预测之前, 需评估轴承退化可信度范围, 准确地区分出轴承在每个阶段的退化状态, 如图 6 所示。




图 6 退化可信度范围

由上图看出, 健康状态的可靠度大约在 100%, 可信度的下降速度基本保持不变; 磨损中期与急剧磨损期的可靠度分别约在 99%~30%与 20%~0 之间, 可信度下降速度急速增大。

7) 利用 PSO_LSSVM 构建预测模型。由于最小二乘支持向量机(LSSVM)中 γ 和 δ 两参数对预测结果起着关键性作用, 为了能够实现自动优化参数, 所以采用粒子群算法 (particle swarm optimization, PSO) 优化 LSSVM 参数, 从而提高预测性能。

为了验证笔者所提方法的有效性, 分别与文献 [9-10]所提方法做了对比。3 种方法的 RUL 预测结果如图 7—12 所示。




图 7 文中方法的 RUL 预测结果




图 8 文中方法的 RUL 预测误差




图 9 文献[9]所提方法的 RUL 预测结果




图 10 文献[9]所提方法的 RUL 预测误差




图 11 文献[10]所提方法的 RUL 预测结果




图 12 文献[10]所提方法的 RUL 预测误差

从上图得到如下结论:

1) 从图 7、9 与 11 中可以看出, 随着时间的推移都有明显的下降趋势, 在 80 min 后开始逐渐围绕实际寿命上下波动, 这是因为轴承处于健康状态时退化信息较少。

2) 从误差图中看出, 图 8 与 10 的误差在故障发生后较接近, 且图 8 相对于图 10 在健康阶段的误差起伏范围较大。这是因为利用 K_均值聚类算法能够识别方差值中的离群点, 而在文献[10]中未提到识别数据中的离群点, 所以图 7 的结果相对于图 9 的结果更加稳定一些。

3) 图 11 的预测结果相对于图 7 的预测结果来看 RUL 预测波动较大。由于笔者利用分段拟合修复虚假波动, 从而获得了健康的退化指标; 但在文献 [9]中只进行了 GMM 聚类识别数据中的离群点, 未从真正意义上获得健康的退化指标, 所以图 7 的预测结果相对来说较为平和。

为了更清楚地说明仿真结果, 根据式(12)–(13) 计算 3 种方法的平均绝对误差(mean absolute error, MAE)和归一化均方根误差(normalized root mean square error, NRMSE)。

$$MAE = \frac{1}{N} \sum_{i=1}^N |R_{\text{predict}} - R_{\text{actual}}|; \quad (12)$$

$$\text{NRMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (R_{\text{predict}} - R_{\text{actual}})^2 / \left(\sum_{i=1}^N R_{\text{predict}} / N \right)} \quad (13)$$

式中： i 为数据集的样本点数 ($i=1, 2, \dots, N$)； N 为总样本数； R_{predict} 和 R_{actual} 分别为轴承的预测 RUL 和实际 RUL。

MAE 是一种稳定的预测评价指标，MAE 越小，预测模型越可靠；相反，预测模型不稳定。NRMSE 评价预测模型的强弱，NRMSE 越小，就越接近完美的模型。3 种方法的 MAE 与 NRMSE 的值如表 1 所示。可以看出，笔者方法相比于其他 3 种方法精度最高。

表 1 3 种方法 MAE 与 NRMSE 的值

方法	文中方法	文献[9]	文献[10]
MAE	0.075 8	0.272 7	0.111 7
NRMSE	0.210 4	0.924 6	0.297 5

3 结束语

为了准确地评价轴承的退化趋势与预测其 RUL，主要从数据预处理、构建健康退化指标、退化状态评估 3 方面对轴承 RUL 预测进行研究，提出基于性能退化指标的轴承 RUL 预测模型，研究要点如下：

1) 采用 LMD 方法进行数据预处理，为后续的预测模型提供高质量的数据源。

2) 利用基于 ANN 训练的注意力机制模型得到高质量的特征量。并引入 K_均值聚类算法与分段拟合获得健康的 HI。

3) 为提高轴承 RUL 预测的可靠性，建立 GM 回归模型，得到轴承退化可信度范围。最后，建立基于 HI 的 PSO_LSSVM 模型预测轴承 RUL。轴承全寿命周期振动数据集完成了 3 组对比实验，验证了该方法的准确性。

未来将针对工业界普遍存在的数据不全等问题，探索缺乏足够数据条件下的人工智能 RUL 预测。

参考文献：

[1] 陈进. 机械设备振动监测与故障诊断[M]. 上海: 上海交通大学出版社, 1999: 1-252.
 [2] 苗学问, 王大伟, 洪杰. 滚动轴承寿命理论的发展[J].

轴承, 2008, 12(3): 47-52.

- [3] ZHONG K, HAN M. Data-driven based fault prognosis for industrial systems: a concise overview[J]. IEEE/CAA Journal of Automatica Sinica, 2020, 17(2): 330-345.
 [4] TIAN J, MORILLO C, AZARIAN M H, et al. Motor Bearing Fault Detection Using Spectral Kurtosis-Based Feature Extraction Coupled With K-Nearest Neighbor Distance Analysis[J]. IEEE Transactions on Industrial Electronics, 2016, 63(3):1793-1803.
 [5] PAN Z, MENG Z, CHEN Z. A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings[J]. Mechanical Systems and Signal Processing, 2020, 144(11): 106899.
 [6] LIU H, LIU Z, JIA W, et al. Remaining Useful Life Prediction Using a Novel Feature-Attention- Based End-to-End Approach[J]. IEEE Transactions on Industrial Informatics, 2021, 17(2): 1197-1207.
 [7] LIU Y, HU X, ZHANG W. Remaining useful life prediction based on health index similarity[J]. Reliability Engineering & System Safety, 2019. 185: 502-510.
 [8] YANG C, MA J, WANG X, et al. A novel based-performance degradation indicator RUL prediction model and its application in rolling bearing[J]. ISA Transactions, 2022, 121: 349-364.
 [9] PENG Y, CHENG J, LIU Y, et al. An adaptive data-driven method for accurate prediction of remaining useful life of rolling bearings[J]. Frontiers of Mechanical Engineering, 2018, 13(2): 301-310.
 [10] YAN M, WANG X, WANG B, et al. Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model[J]. ISA Transactions, 2020, 98: 471-482.
 [11] 王奉涛, 王贝, 敦泊森. 改进 Logistic 回归模型的滚动轴承可靠性评估方法[J]. 振动、测试与诊断, 2018, 38(1): 123-129.
 [12] DONG S, LUO T. Bearing degradation process prediction based on the PCA and optimized LSSVM model[J]. Measurement, 2013, 46(9): 3143-3152.
 [13] LI X, MA J, WANG X, et al. An improved local mean decomposition method based on improved composite interpolation envelope and its application in bearing fault feature extraction[J]. ISA Transactions, 2020, 97: 365-383.
 [14] LIU S, HOU S, HE K, et al. L-Kurtosis and its application for fault detection of rolling element bearings[J]. Measurement, 2018, 116: 523-532.
 [15] 雷亚国, 韩天宇, 王彪. XJTU-SY 滚动轴承加速寿命试验数据集解读[J]. 机械工程学报, 2019, 55(16): 15-20.