

DOI:10.3969/j.issn.1001-4551.2024.05.011

基于 TFER 及退化趋势相似性分析的轴承剩余使用寿命预测*

刘强强,谷艳玲*,张品杨

(沈阳工业大学机械工程学院,辽宁沈阳110870)

摘要:为了解决传统退化指标对轴承退化起始点的敏感性差,以及退化指标趋势偏移导致无法准确预测风力机轴承剩余使用寿命(RUL)的问题,提出了一种基于 Teager 能量算子-故障能量比(TFER)与退化趋势(DT)相似性检测相结合的双指数轴承 RUL 预测方法。首先,通过计算原始信号的 TFER 值,根据 4σ 原则确定轴承退化起始点,提取了 TFER 值趋势特征作为退化指标;然后,采用历史 TFER 值拟合双指数退化模型,通过分析最新 TFER 值与拟合曲线的相似性,选取了最佳 DT 段;最后,通过外推相似性最佳的 DT 段至失效阈值,进行了风力机轴承 RUL 预测。实验结果表明:该预测方法对退化起始时间点的检测精度达到 98%,与原始指数模型、长短期记忆神经网络(LSTM)以及支持向量回归(SVR)相比,该方法在轴承 RUL 预测精度上分别提高了 10.04%、6.29%、5.22%。该方法不仅提升了风力机轴承的预测性维护精度,还对降低运营成本和提高维护效率提供了有力支撑。

关键词:风力机轴承;剩余使用寿命;双指数预测方法;Teager 能量算子;故障能量比;退化趋势相似性检测;相似性分析

中图分类号:TH133.3

文献标识码:A

文章编号:1001-4551(2024)05-0853-09

Bearing remaining using life prediction method based on TFER and degradation trend similarity analysis

LIU Qiangqiang, GU Yanling, ZHANG Pinyang

(School of Mechatronics Engineering, Shenyang University of Technology, Shenyang 110870, China)

Abstract: To address the challenges posed by the poor sensitivity of traditional degradation indices to the onset of bearing degradation and the inability to accurately predict the remaining using life (RUL) of wind turbine bearings due to trend shifts in degradation indices, a bi-exponential method for predicting bearing RUL was proposed. This method was based on the combination of Teager's energy arithmetic-ratio of failures to energy (TFER) and degradation trend (DT) similarity detection. Firstly, the TFER value of the original signal was calculated to determine the bearing degradation starting point following the 4σ principle. The trend feature of the TFER value was then extracted as a degradation indicator. Subsequently, a bi-exponential degradation model was fitted using historical TFER values. Then, the best DT segment was chosen by analyzing the similarity between the latest TFER values and the fitted curve. Finally, the wind turbine bearing RUL was predicted by extrapolating the DT segment with the best similarity to the failure threshold. The experimental results show that the prediction method achieves 98% accuracy in detecting the degradation onset time point, and improves 10.04%, 6.29%, and 5.22% in bearing RUL prediction accuracy compared with the original exponential model, the long-and short-term memory neural network (LSTM), and the support vector regression (SVR), respectively. This method not only improves the accuracy of predictive maintenance of wind turbine bearings, but also provides strong support for reducing operating costs and improving maintenance efficiency.

Key words: wind turbine bearing; remaining using life (RUL); bi-exponential predicting method; Teager energy operator; failure-to-energy ratio (FER); similarity analysis; degradation trend (DT) similarity detection

0 引言

由于低生产成本和低碳排放的特点,风能资源已

成为电力公司能源组合中的重要组成部分。然而风力发电机所使用的轴承在运行过程中面临着恶劣的工作条件,其中包括风速的变化所带来的振动和冲击。这

收稿日期:2023-09-19

基金项目:国家自然科学基金青年科学基金资助项目(52305066)

作者简介:刘强强(1998-),男,河南南阳人,硕士研究生,主要从事风电机组智能运维等方面的研究。E-mail:1738713676@qq.com

通信联系人:谷艳玲,女,博士,副教授,博士生导师。E-mail:Guyanling@sut.edu.cn

些极端载荷使得轴承超过其设计极限,导致其失效率高于预期^[1]。

据报道,发电机与齿轮箱高速轴之间的不对准以及高速轴轴承容易受到循环载荷的共同作用,使得高速轴轴承发生故障的几率较高^[2]。这种故障对维护计划产生了不利影响,降低了操作安全性,并导致发电量下降。因此,减少组件故障对系统的影响,可提高可靠性、减少停机时间,并为轴承提供可靠的预测和健康管理。

为了实现对轴承剩余使用寿命(remaining useful life, RUL)的准确预测,研究人员提出了多种预测建模技术,包括基于物理模型方法、数据驱动方法和混合模型方法^[3]。

数据驱动方法是一种基于测量数据的退化预测方法,通过分析机械系统运行数据的动态特性^[4],从数据中推导出机器的退化过程,它不需要深入研究退化机理或依赖大量先验知识。例如, YANG Feng 等人^[5]提出了动态退化指标平滑方法,通过将退化指标映射到剩余使用时间的的方法来完成预测。PAN Z 等人^[6]利用相对均方根作为滚动轴承运行状态的评价指标,通过单变量预测原理和反馈极限学习机模型分别对滚动轴承的劣化趋势进行了短期预测;然而,以上研究都对大量高质量的数据提出了要求。由于风力发电机组通常在恶劣的工作环境下运行,在复杂的工况条件下获取大量高质量的训练数据相当困难。因此,在这种情况下,数据驱动模型并不适用于风力机轴承 RUL 预测。

混合模型是在轴承 RUL 预测的不同阶段,依据每个阶段的不同特点采用最合适的模型,充分发挥每个模型的特点。例如 YAN Ming-ming 等人^[7]通过无量纲测量评估了轴承退化阶段,使用支持向量机(support vector machine, SVM)对轴承退化状态进行了评估分类,根据分类结果优化了退化跟踪模型,实现了轴承 RUL 预测目的;然而,以上研究的高复杂性、大量数据需求以及对实时性的要求,使得混合预测模型并不适合用于风电机组轴承 RUL 预测。

相比之下,基于模型的预测方法是利用数学模型来描述部件或系统的衰退趋势,并通过历史数据对模型参数进行实时更新的方法。这种方法能够充分利用经验知识与历史数据之间的关系,并不需要大量的训练数据就能够完成轴承 RUL 预测。WANG Gang 等人^[8]通过计算振动信号的峰度和均方根的方法,自适应确定首次预测的时间,构建了梯度下降法优化指数退化模型的参数,预测了轴承 RUL;尽管 WANG Gang

等人采用自适应方法确定了首次预测时间,但该方法的不足之处在于传统的退化指标(如峰度和均方根等)在早期微弱故障的周期性脉冲信号方面敏感性差。此外,由于当前退化趋势(degradation trend, DT)在受到各种因素的影响下会造成偏移,使当前 DT 与拟合模型推导出的假设演化轨迹之间产生偏差。传统的方法是采用以历史样本为主导的退化模型的参数来优化、修正偏差,然而拟合退化模型的参数几乎不能被修改以调整到当前 DT。这忽略了当前 DT 样本对参数的影响,使得预测的准确性下降。

为了解决以上问题,笔者提出一种基于 Teager 能量算子-故障能量比(Teager energy operator-fault energy ratio, TFER)和 DT 相似性分析相结合的双指数轴承 RUL 预测方法。

首先,笔者运用 Teager 能量算子与故障能量比构建 TNER 退化指标,以表征风电轴承的退化过程;接着,根据 4σ 原则确定轴承的退化起始点,从而启动轴承 RUL 预测机制;最后,通过基于相似度分析的双指数退化模型进行风电轴承的 RUL 预测;实验阶段利用风电轴承实验数据进行验证,通过与其他轴承 RUL 预测方法的比较,验证该模型的优越性。

1 理论基础

1.1 TFER 轴承性能退化指标

Teager 能量谱基于非线性运算,通过计算信号的瞬时功率来捕捉信号的调制特征。对于周期性脉冲信号,Teager 能量谱可以很好地反映出脉冲的周期性,并抑制噪声与非调制成分。

对于原始时间序列 $x(t) = \{ \sum_{i=1}^n \sum_{j=1}^m x_{ij}(t) \}$, 数据集中有 n 个样本,其包括 m 个特征。

Teager 能量谱的计算步骤如下:

根据 Teager 能量算子的定义^[9], Teager 能量序列可按式(1)进行计算:

$$\tilde{x}(t) = \psi[x(t)] = [x'(t)]^2 - x(t)x''(t) \quad (1)$$

式中: $\tilde{x}(t)$ 为 Teager 能量序列; $x'(t)$, $x''(t)$ 为原始时间序列 $x(t)$ 的一阶、二阶导数。

通过对 Teager 能量序列进行快速傅里叶变换(fast Fourier transform, FFT),获得 Teager 能量谱:

$$|F(u, v)| = [R^2(u, v) + I^2(u, v)] \quad (2)$$

式中: $R^2(u, v)$, $I^2(u, v)$ 为 FFT 的实部与虚部。

基于上述原因,引入故障能量比概念(fault energy ratio, FER)^[10]。FER 反映故障特征频率能量在频谱

总能量中的占比,FER 值越高,意味着故障程度越严重。FER 的参数 p 决定频谱中前 p 个故障特征频率占整个频谱的总能量的比例。为了精确地反映轴承故障程度,通常希望能够在频谱中检测轴承缺陷频率的三次谐波,所以此处笔者取 $p=3$ 。

FER 的具体表达式如下:

$$FER = \frac{E}{E^*} \quad (3)$$

式中: E 为 Teager 频谱序列前三次的幅值能量之和; E^* 为 Teager 能量谱振幅的总能量,通过计算 Teager 能量谱的自相关函数(auto correlation function, ACF) 可以获得信号的总能量^[11]。

信号总能量计算公式如下:

$$r_x(\tau) = \int_{-\infty}^{+\infty} \hat{e}(t) \hat{e}(t + \tau) d\tau \quad (4)$$

式中: τ 为 ACF 的时滞。

此外,通过 ACF 的定义,可以从包络信号的自相关函数的最大值位置找到信号的最佳周期性脉冲。包络谐波比(envelope harmonic to noise ratio, EHNR) 通过 ACF 能够计算出包络信号中的故障特征能量在频谱总能量的占比。然而,由于 ACF 对强噪声的鲁棒性弱,这使得 EHNR 在表征轴承状态时效果较差。为了在 Teager 能量谱中获得准确的故障特征能量,可以根据 Teager 能量谱总能量 $r_x(0)$ 和 FER 计算信号中的故障特征能量、噪声能量,再计算出 TFER^[12]。

TFER 数学表达式为:

$$TFER = \frac{FER \cdot r_x(0)}{r_x(0) - FER \cdot r_x(0)} \quad (5)$$

TFER 的数值大小能够反映轴承性能退化程度。与传统退化指标相比,它是一种稳定性好、单调性强的轴承运行状态指标,可以确定早期故障的起始点,提高故障检测的准确性,并避免虚假报警。

1.2 曲线与 Fréchet 距离理论

设 $\pi \subseteq R^d$ 为曲线 π 从区间 $[0,1]$ 到 R^d 的连续映射。重新参数化是一个连续的一对一函数 $f: [0,1] \rightarrow [0,1]$,使得 $f(0)=0$ 且 $f(1)=1$ 。给定两条曲线 π 和 σ 的两个重新参数化 f 和 g ,分别定义它们的宽度,计算为:

$$width_{f,g}(\pi, \sigma) = \max_{s \in [0,1]} \|\pi(f(s)) - \sigma(g(s))\| \quad (6)$$

这可以解释为遛狗所需皮带的最大长度,其中狗的轨迹是由 f 沿着曲线 π 形成,而遛狗人轨迹则根据 g 沿着 σ 形成。在这个类比中,Fréchet 距离是允许这样行走的最短皮带的长度。

形式上,给定 R^d 中的两条曲线 π 和 σ ,两条曲线

之间的 Fréchet 距离^[13] 表达式如下所示:

$$d_F(\pi, \sigma) = \min width_{f,g}(\pi, \sigma) \quad (7)$$

式中: f, g 为曲线 π 和 σ 保持方向的重新参数化,且 $f: [0,1] \rightarrow [0,1], g: [0,1] \rightarrow [0,1]$ 。

2 风力机轴承 RUL 预测方法

笔者所提出的风力机轴承 RUL 预测流程示意图如图 1 所示。

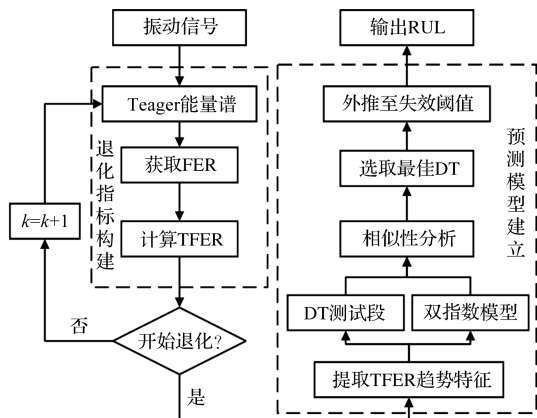


图 1 TFER-DT 轴承 RUL 预测方法

Fig. 1 TFER-DT bearing RUL prediction method

风力机轴承 RUL 预测方法主要由两部分组成,即 TNER 退化指标的提取与轴承 RUL 预测模型的建立。

首先,通过风力机轴承振动信号获得 Teager 能量谱、获取 FER,计算 TFER,完成退化指标的构建;然后,判断退化指标是否达到退化阈值,决定是否启动轴承 RUL 预测机制;若判定退化开始,则提取历史 TFER 值趋势特征,将其用于拟合双指数退化模型;最后,提取当前最新 TFER 值作为 DT 测试段,并且与拟合曲线逐段进行相似性分析,选取退化模型上与测试段相似性最佳的片段作为最佳 DT,外推 DT 至失效阈值,计算轴承 RUL。

2.1 退化起始点检测

轴承退化一般分为两个阶段,正常阶段与退化阶段。而正常阶段与退化阶段的转换时间点就是所谓的退化起始点。

为了检测轴承退化起始点,引入一个特定的阈值来检测退化指标。当退化指标超过特定阈值时,就表示轴承进入退化期。其中特定阈值的确定,根据高斯 4σ 准则^[14],需要计算轴承在正常工作状态下 TFER 的平均值 μ 和标准差 σ ,然后将报警阈值设置为 $\mu + 4\sigma$ 。

为了提高检测退化起始点的准确性,有学者规定,当监测到 TFER 连续出现 5 次超过异常阈值的情况

时,则认定轴承进入退化期^[15]。该机制可以提高轴承退化开始时间的识别精度,并减少异常数据对判断是否进入退化阶段的影响。

2.2 退化指标构建

目前,学者们已经提出了多种信号处理方法来提取轴承预测所需的特征。其中,常用的特征包括时域振动加速度信号的均方根、相对均方根以及最新提出的 EHNR。然而,此类指标对轴承早期故障特征不敏感,同时会因为不稳定造成虚假报警。

为了避免上述情况的发生,笔者提出了从振动信号中提取 TFER 作为退化指标的方法,它能够准确反映轴承的退化状态。相对于传统退化指标而言,该指标能够更敏感地检测出轴承的早期缺陷,并且具有较低的误报率。此外,由于 TFER 呈现一种振荡上升的趋势,直接使用测量值无法准确有效地体现轴承退化趋势及区分退化阶段。

为了更好地表征轴承状态,笔者采用移动平移法构造出一条 TFER 趋势线,它既能够消除数据中的波动和噪音,又能够揭示出 TFER 退化指标的整体趋势。该方法极大地提高了 TFER 作为退化指标能够提高轴承故障预测的准确性和可靠性。

2.3 基于相似性分析的轴承 RUL 预测

当轴承被识别为劣化时,会触发轴承 RUL 预测机制。为了描述退化进程,笔者采用双指数退化模型,因为它不仅可以捕捉轴承的退化趋势,而且易于用较少的样本进行拟合^[16]。其数学表达式如下:

$$H(t) = a \exp(bt) + c \exp(dt) \quad (8)$$

式中: $H(t)$ 为时间 t 时对应的退化指标值; a, b, c, d 为需要由具有线性递减惯性权重的粒子群优化算法确定的参数^[17]。

一旦双指数退化模型被成功拟合,轴承的 RUL 可以由外推双指数退化曲线的失效阈值进行推导。由于当前 DT 的偏移,这种预测结果有时并不令人满意,而通过历史数据优化后的退化模型参数却忽略了当前 DT 对退化模型的影响^[18]。因此,在考虑双指数退化模型之前,使用原始数据拟合退化模型的 RUL 预测是不准确的。为了解决这个问题,笔者提出了具有 Fréchet 距离的退化指标相似性分析方法,以此来自适应地检测轴承的退化趋势^[19]。

Fréchet 距离的计算过程如下:

- 1) 定义一个距离函数 $d(p, q)$, 用于计算曲线上两个点 p 和 q 之间的距离;
- 2) 构建一个距离矩阵 D , 其中 $D[i][j]$ 表示曲线

A 中的第 i 点与曲线 B 中的第 j 点之间的距离;

3) 定义一个路径矩阵 P , 其中 $P[i][j]$ 表示从曲线 A 中的第 1 个点到第 i 点, 以及从曲线 B 中的第 1 个点到第 j 点的最短路径的长度;

4) 初始化路径矩阵 P 的第一行和第一列, 即 $P[1][j]$ 和 $P[i][1]$, 其中 $1 \leq i \leq m, 1 \leq j \leq n, m$ 为曲线 A 的点数, n 为曲线 B 的点数;

5) 通过动态规划的方法计算路径矩阵 P 。Fréchet 距离为 $P[m][n]$, 即路径矩阵 P 的最后一个元素。

从上述 Fréchet 距离的计算方法不难看出, 该计算方法相对于均方根误差、余弦误差等相似性计算方法具有优势。Fréchet 距离并没有单纯地考虑点之间的相似性, 还考虑到两条曲线上的点构成的曲线发展趋势的相似性。这也成为了 Fréchet 距离在退化趋势相似性分析上的优势所在。

为了分析相似性, 笔者将轴承的最后 q 个退化指标值作为测试段截断, 从退化起始点开始逐点与拟合的退化曲线进行比较。具体地, 令 Ts_i 表示时间 t 处的测试段, 并且 Fc_i 表示从 $t+i-q$ 到 $t+i$ 的拟合曲线的 q 个预测退化指标值。其中 i 为与 Ts_i 段最相似的 Fc_i 段时, 该段的终点所对应的时间点为 t 。

然后, 它们之间的相似性^[13]计算如下式所示:

$$\theta_i(Fc_i, Ts_i) = \inf \max D(Fc_i(\tau(x)), Ts_i(\varphi(x))) \quad (9)$$

式中: $\tau(x), \varphi(x)$ 为两个单调递增函数, $\tau, \varphi, x \in [0, 1], \tau: [0, 1] \rightarrow Fc, \varphi: [0, 1] \rightarrow Ts; D(\cdot)$ 为欧几里德距离, 较小的 Fréchet 距离意味着 Fc_i 和 Ts_i 的相似性较高。

所选时间点 $t+i$ 代表最合适的 DT, 命名为 mad ; 因此, 时间点 t 处 RUL 可以用下式计算^[20]:

$$TI_t = \inf \{ r; D(mad+r) - D(mad) \geq \Delta DI_t | DI_t \} \quad (10)$$

$$\Delta DI_t = FTH - DI_t \quad (11)$$

式中: TI_t 为 t 处轴承 RUL; DI_t 为 t 处获得的退化指标值; $D(mad+r)$ 为 $mad+r$ 处的预测 DI 值; FTH 为失效阈值; ΔDI_t 为当前时间到轴承失效时的 DI 变化量, 可以用来预测 RUL 的接近程度。

最后, 通过将 TI_t 与 t 相加而获得在时间 t 处轴承的剩余寿命 TTF_t , 其计算方法如下:

$$TTF_t = TI_t + t \quad (12)$$

基于退化趋势相似性检测原理示意图如图 2 所示。

由图 2 可知: 在 $t = 489$ h 时, 首先用历史数据拟合降解曲线, 然后, 由最新的几个 DI 点组成的测试段 Ts_t ,




图2 相似性检测原理示意图

Fig.2 Schematic diagram of similarity detection principle

沿着拟合曲线滑动,以计算它们的相似度,在图2中表示为S1、S2和S3,假设S2是最佳的mad,则选择拟合曲线的对应点作为DT;最后,可以使用式(8)来预测轴承RUL。

3 实验验证

3.1 实验数据说明

为了验证所提出的轴承RUL预测方法的有效性,笔者采用某风场2.0 MW风力发电机高速轴轴承振动数据对轴承RUL预测方法进行验证。

实验数据细节如下:采样频率为25.6 kHz,每次采样长度为2560,采样间隔为10 min,轴承实际退化起始时间为341 h,跟踪至失效的时间为750 h(约32天)。

风力发电机轴承现场测试图片如图3所示(箭头所示为加速度传感器的安装位置)。



图3 风力发电机轴承现场测试图片

Fig.3 Pictures of wind turbine gearbox bearing field test

3.2 退化指标分析以及对比

轴承全寿命周期大致可以分为三个阶段。轴承全寿命周期TFER值如图4所示。




图4 轴承全寿命周期TFER值

Fig.4 Full life cycle TFER values for bearings

由图4可知:正常运行阶段(0 h ~ 325 h),轴承TFER值较为稳定、幅值波动较小;在退化阶段(326 h ~ 678 h),由于轴承故障尺寸加深和增大,TFER值的幅值波动变大,并呈现上升趋势,这表明轴承失效特征更为明显;在失效阶段(679 h ~ 750 h),轴承的TFER值反复超越失效阈值线(根据历史失效轴承数据,该指标等于1意味轴承失效),这意味着轴承已经进入失效阶段,无法可靠工作。如果不及时处理,将对整个机械系统造成严重危害,直到轴承彻底失效($t = 750$ h)。

考虑到轴承退化的机理,拟合的结果与轴承的物理退化有很好的相关性,这被认为是不可逆的^[20]。图4中的虚线为TFER的趋势线,该曲线具有很好的单调性等特点,拟合的测量值是一个很好的轴承健康指标,可以用于评估轴承的退化程度。

笔者采用均方根值、EHNR等传统退化指标与实验所提的退化指标进行对比研究,以说明该实验所提的TFER退化指标的优越性。

实验数据的均方根值如图5所示。




图5 全寿命周期均方根值

Fig.5 Whole life cycle root-mean-square value

由图5可知:均方根对早期微弱故障脉冲信号敏感性低,无法捕捉早期退化起始点且难以区分轴承退化状态。

实验数据的 EHNHR 值如图 6 所示。




图 6 全寿命周期 EHNHR 值

Fig. 6 Whole life cycle EHNHR values

根据图 6 局部放大图可以看到:当 EHNHR 值连续 5 次超越退化阈值线时,认定星号所标记的 EHNHR 值点所对应的时间点为退化起始点 $t = 359$ h,这与实际退化时间($t = 341$ h)相比晚了 18 h。

而 TFER 退化指标所确定的退化起始点为 $t = 348$ h,仅仅比实际退化时间推迟了 7 h,TFER 退化指标对于早期故障检测的准确度达到 98%。其次,EHNHR 在正常时段有虚警点(图中用黑色圆圈在 EHNHR 测量值中圈出),运行初期 EHNHR 幅值不稳定,整体振荡明显。

综上所述,相对于其他退化指标,该实验采用的 TFER 退化指标对早期轴承微弱故障更加敏感,能够真实地反映轴承整体退化过程,有利于提高轴承 RUL 预测精度。

3.3 轴承 RUL 预测及对比实验

当轴承退化指标达到退化阈值,将触发轴承 RUL 预测机制。

笔者在实验过程中发现,测试段中数据量 q 值的选择对实验结果有一定的影响。为此,笔者选择 $q = 0, 50, 60, 70$ 的数据量对轴承 RUL 进行预测。

不同 q 值轴承的 RUL 预测结果如图 7 所示。




图 7 不同 q 值轴承 RUL 预测结果

Fig. 7 Prediction results of RUL for bearings with different q -values

从图 7 结果中可以得知:当 q 值小,且历史退化趋势波动较大($t = 400$ h ~ 500 h)时,较小的 q 对趋势突变的鲁棒性弱,使得其对退化趋势的修正效果不明显。而过大的 q 值使测试段数据在历史数据中的占比变大,提高了测试段对退化趋势突变的包容性,降低了对当前趋势的反映,同样减弱了退化趋势修正的效果。

综上所述, q 值的选择对最后的预测效果有一定的影响。

当 $q = 50$,轴承退化初期、退化后期的 RUL 预测示意图如图 8 所示。




图 8 $q = 50$ 时轴承不同退化时间预测示意图

Fig. 8 Schematic diagram of different degradation time prediction of bearing at $q = 50$

由图 8 可知:图 8(a)中详细描述了在时间 $t = 348$ h 时的轴承 RUL 预测过程。首先,可用的 DI 值,其显示为三角形的历史数据,被用来拟合双指数退化模型;接下来,将最后的 DI 区段截断为 Ts_i ,用于对拟合曲线进行 DT 相似性检测,其在图 8(a)中由矩形框表示。而矩形圈出的 Ts_i 用于逐点计算与拟合曲线的相似性,以进行适当的 DT 检测。

在选择了具有最佳相似度 $S1$ 的 mad 之后,可以利用式(8)来获取 TI_i 。公式中的 ΔDI_i 被设置为时间 t 处的 DI 值与失效阈值之间的差值,并且可以通过外推拟合曲线以预测未来的 DI 值。因此,将 TI_i 计算为从 mad 到预测 DI 值增加为 ΔDI_i 的时间点的间隔。最

后,利用式(12)推导出在时间 t 处的 RUL。

从图 8 可以看出:在每个时间点,TFER 可以自适应地检测适当的退化趋势,这比没有退化趋势检测的原始预测方法更能准确地预测轴承 RUL 结果。

笔者采用 TFER 退化指标和自适应退化趋势检测组成的技术来实现轴承 RUL 预测目的,并且设计了两组实验来说明该方法的优点。

基于不同退化指标的 RUL 预测结果如图 9 所示。




图 9 不同退化指标 RUL 预测结果

Fig. 9 Results of RUL prediction for different degradation indicators

由图 9 可知:第一组实验将预测模型固定,退化指标设为自变量。两种退化指标的不同点在于 TFER 提取故障特征频率三次谐波能量之和,而 EHNH 使用 ACF 定位轴承故障引起的周期性冲击。

两种退化指标的轴承 RUL 预测结果如表 1 所示。

表 1 退化指标预测对比

Table 1 Comparison of degradation indicator projections (%)

退化指标	TFER	EHNH
平均误差	5.04	5.98

EHNH 检测的退化起始点滞后于轴承故障实际退化起始点,从而导致轴承 RUL 预测机制启动滞后。

从表 1 中可以得知:TFER 预测轴承 RUL 的平均误差为 5.04%,而 EHNH 退化指标的平均误差却为 5.98%。

从预测结果中可以看出,由于退化起始点检测的准确性,使得 TFER 相对于 EHNH 能够更加精准地反映轴承真实退化趋势,轴承 RUL 预测更加准确。

第二组实验预测结果如图 10 所示。

在图 10 中,笔者统一采用 TFER 作为退化指标,分别使用改进双指数模型与原始指数模型、LSTM 模型、SVR 模型进行轴承 RUL 预测。

从两种指数退化模型预测结果中不难看出,起始预测阶段,由于正常期退化趋势平稳,退化早期缺乏历史数据,使得指数退化模型 RUL 预测结果相对误差




图 10 不同预测模型 RUL 预测结果

Fig. 10 RUL prediction results of different prediction models

偏大。

随着轴承发展进入退化中后期,改进双指数退化模型采用自适应退化趋势检测方法,相对于原始指数模型,其能够很好地抑制这种改变,预测效果相对误差小。

进入失效期,TFER 值指数级增长,改进双指数退化模型更加贴合拟合 DT,轴承 RUL 预测精度高。而原始指数退化模型采用以历史退化指标数据作为主导来优化模型参数,没有有效考虑当前 DT 改变,使得预测结果有一定的迟滞效果,轴承 RUL 预测精度低。

LSTM 方法的参数设置总结如下:采用网格搜索算法确定最佳参数组合,即通过交叉验证,评估每个组合的性能,选出最优参数组合;使用神经元数分别为 24 和 16 的 2 个 LSTM 层处理输入监测数据,然后使用一个全连接层进行 RUL 预测。

SVR 模型采用高斯函数,要利用 Adma 算法对参数进行优化。但由于 LSTM 与 SVR 模型对参数要求高、数据需求量较大,会造成 RUL 预测效果不佳。

基于 TFER 的双指数退化预测模型与其他预测模型,得到的风力机轴承 RUL 预测对比结果如表 2 所示。

表 2 模型预测结果对比

Table 2 Comparison of model prediction results (%)

预测模型	TFER	指数	SVR	LSTM
平均误差	5.04	15.08	10.26	11.37

从表 2 中可以看出:基于 TFER 的双指数退化预测模型的风力机轴承 RUL 预测误差最小,相比于其他传统模型,其在预测精度上分别提高了 10.04%、5.22%、6.29%。

实验结果证明,该方法是有效的。

4 结束语

为解决传统退化指标对轴承早期微弱故障的识别准确率不足,以及轴承 RUL 预测受到趋势偏移影响的问题,笔者提出了一种基于 TFER 和 DT 相似性分析相结合的双指数轴承 RUL 预测方法,并且采用实际的风电轴承数据,验证了该方法在早期故障诊断和轴承 RUL 预测精度方面的优越性(相对于其他方法)。

研究结论如下:

1) 利用 TFER 轴承退化指标检测到的风电轴承退化点比实际退化点晚了 7 h。相较之下,EHNR 退化指标延迟了 18 h,而均方根值则无法区分轴承退化阶段。上述结果显示了 TFER 退化指标对轴承退化起始点的高敏感性;

2) TFER 退化指标对轴承退化状态表征的滞后性较弱。这使得 TFER 退化指标能够及时启动轴承 RUL 预测机制。具体而言,TFER 的预测误差为 5.04%,相较于 EHNR 的预测误差 5.98% 更小;

3) 双指数退化模型通过联合相似性退化趋势检测法对 TFER 退化曲线进行了预测,提高了该模型对退化趋势突变的适应性。与原始指数退化模型、LSTM 和 SVR 模型相比,该模型在风电轴承 RUL 预测精度上分别提高了 10.04%、11.37% 和 10.26%。

该方法更准确地捕捉了轴承性能的退化趋势,为提高轴承寿命预测的精度提供了有效的解决方案。

接下来笔者将致力于研究智能化端到端的轴承监测系统,并且结合传感器技术、物联网和云计算等技术,对轴承状态进行实时监测和判断,以提供更加准确、可靠的轴承 RUL 预测结果。

参考文献 (References):

[1] SAIDI L, BEN A J, BECHHOEFER E, et al. Wind turbine high-speed shaft bearings health prognosis through a spectral kurtosis-derived indices and SVR [J]. *Applied Acoustics*, 2017, 120(5): 1-8.

[2] WILLIAM L, XING Yi-hang, CHRIS M, et al. Three-dimensional bearing load share behaviour in the planetary stage of a wind turbine gearbox [J]. *IET Renewable Power Generation*, 2013, 7(4): 359-369.

[3] LEI Ya-guo, LI Nai-peng, LIANG Guo, et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction [J]. *Mechanical Systems and Signal Processing*, 2018, 104(5): 799-834.

[4] 蒋全胜,许伟洋,朱俊俊,等. 基于动态加权卷积长短时记忆网络的滚动轴承剩余寿命预测方法[J]. *振动与冲击*,

2022, 41(17): 282-291.

JIANG Quan-sheng, XU Wei-yang, ZHU Jun-jun, et al. Residual life prediction method for rolling bearings based on dynamically weighted convolutional long-and short-term memory networks [J]. *Vibration and Shock*, 2022, 41(17): 282-291.

[5] YANG Feng, HABIBULLAH M S, ZHANG Tian-you, et al. Health index-based prognostics for remaining useful life predictions in electrical machines [J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(4): 2633-2644.

[6] PAN Z, MENG Z, CHEN Z, et al. 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(10): 106899.

[7] YAN Ming-ming, WANG Xin-gang, WANG Bing-xiang, et al. Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model [J]. *ISA Transactions*, 2020, 98(3): 471-482.

[8] WANG Gang, XIANG Jia-wei. Remain useful life prediction of rolling bearings based on exponential model optimized by gradient method [J]. *Measurement*, 2021, 176(5): 109161.

[9] LIU Feng. Multipoint Optimal Minimum Entropy Deconvolution and Teager Energy Operator for the Incipient Fault Diagnosis of Planetary Gearbox [C]//2021 40th Chinese Control Conference (CCC), Shanghai, China, 2021: 4339-4343.

[10] MIAO Yong-hao, ZHAO Ming, LIN Jing, et al. Application of an improved maximum correlated kurtosis deconvolution method for fault diagnosis of rolling element bearings [J]. *Mechanical Systems & Signal Processing*, 2017, 92(8): 173-195.

[11] XU Xiao-qiang, ZHAO Ming, LIN Jing, et al. Envelope harmonic-to-noise ratio for periodic impulses detection and its application to bearing diagnosis [J]. *Measurement*, 2016, 91(9): 385-397.

[12] 董绍江,裴雪武,汤宝平,等. 基于 FNER 性能退化指标及 IDRSN 的滚动轴承寿命状态识别方法[J]. *机械工程学报*, 2021, 57(15): 105-115.

DONG Shao-jiang, PEI Xue-wu, TANG Bao-ping, et al. A rolling bearing life state identification method based on FNER performance degradation index and IDRSN [J]. *Journal of Mechanical Engineering*, 2021, 57(15): 105-115.

[13] BUCHIN K, BUCHIN M, WENK C. Computing the Fréchet distance between simple polygons in polynomial time [J]. *Computational Geometry*, 2006, 41(1-2): 2-20.

- [14] LEI Ya-guo, JIA Feng, LIN Jing, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data [J]. IEEE. Transactions on Industrial Electronics, 2016, 63(5):3137-3147.
- [15] 吕明珠, 苏晓明, 陈长征, 等. 基于 PCA-UPF 的风力机轴承剩余寿命预测方法 [J]. 太阳能学报, 2021, 42(2): 218-224.
- LV Ming-zhu, SU Xiao-ming, CHEN Chang-zheng, et al. Residual life prediction method for wind turbine bearings based on PCA-UPF [J]. Journal of Solar Energy, 2021, 42(2):218-224.
- [16] WANG Ping, LONG Zhi-qiang, WANG Gao. A hybrid prognostics approach for estimating remaining useful life of wind turbine bearings [J]. Energy Reports, 2020, 6(12): 173-182.
- [17] LIU Na, LUO Fei, DONG Wei-chao. Cloud Task Scheduling Algorithm Based on Squid Operator and Nonlinear Inertia Weight [C]//2019 IEEE. Symposium Series on Computational Intelligence (SSCI), Xiamen, China, 2019:3104-3109.
- [18] 宓乐峰, 孙丹, 王旭, 等. 基于正交试验的波纹管结构参数优化及疲劳寿命分析 [J]. 压力容器, 2023, 40(3):38-46.
- MI Le-feng, SUN Dan, WANG Xu, et al. Structural parameter optimization and fatigue life analysis of bellows based on orthogonal test [J]. Pressure Vessel Technology, 2023, 40(3):38-46.
- [19] BENJAMIN, RAICHEL, SARIEL, et al. The Fréchet distance revisited and extended [J]. Acm Transactions on Algorithms, 2014, 10(1):1-22.
- [20] CHEN Zhi-peng, ZHU Hai-ping, FAN Liang-zhi, et al. Health indicator similarity analysis-based adaptive degradation trend detection for bearing time-to-failure prediction [J]. Electronics, 2023, 12(7):1569.

本文引用格式:

刘强强, 谷艳玲, 张品杨. 基于 TFER 及退化趋势相似性分析的轴承剩余使用寿命预测 [J]. 机电工程, 2024, 41(5):853-861.

LIU Qiangqiang, GU Yanling, ZHANG Pinyang. Bearing remaining using life prediction method based on TFER and degradation trend similarity analysis [J]. Journal of Mechanical & Electrical Engineering, 2024, 41(5):853-861.

《机电工程》杂志; <http://www.meem.com.cn>

(上接第 835 页)

- [15] 薛召, 贾文昂, 李展尚. 基于模糊单神经元 PID 的比例同步控制研究 [J]. 机床与液压, 2022(11):50.
- XUE Zhao, JIA Wen-ang, LI Zhan-shang. Research on proportional synchronous control based on fuzzy single neuron PID [J]. Machine Tool and Hydraulic, 2022(11):50.
- [16] SIROUSPOUR M, SALCUDEAN S. On the Nonlinear Control of Hydraulic Servo-systems [C]//Proceedings of International Conference on Robotics and Automation. IEEE. 2000, 2:1276-1282.
- [17] 张海洋, 梁全, 王志科, 等. 基于递推最小二乘法的阀控缸液压系统控制策略 [J]. 机电工程, 2023, 40(11): 1743-1751.
- ZHANG Hai-yang, LIANG Quan, WANG Zhi-ke, et al. Control strategy of valve-controlled cylinder hydraulic system based on recursive least squares method [J]. Mechanical and Electrical Engineering, 2023, 40(11): 1743-1751.
- [18] 陈星. 飞机舵机电液负载模拟装置故障诊断策略研究 [J]. 液压气动与密封, 2023, 43(8):109-112.
- CHEN Xing. Research on fault diagnosis strategy of electro hydraulic load simulator for aircraft steering gear [J]. Hydraulics Pneumatics & Seals, 2023, 43(8):109-112.
- [19] 吴珊. 基于 MATLAB 的电动汽车动力电池电液固定装置抗振与密封性能实验研究 [J]. 液压气动与密封, 2023, 43(5):29-32.
- WU Shan. Anti vibration and sealing performance experimental study of electric vehicle power battery fixing device for electric vehicle based on MATLAB [J]. Hydraulics Pneumatics & Seals, 2023, 43(5):29-32.
- [20] WOS P, DINDORF R. Motion synchronization for electro-hydraulic servo-drives [J]. Journal of Engineering Mechanics, 2019:407-410.
- [21] 徐洪涛, 李延民. 基于 AMESim 和反步控制器的阀控电液伺服系统滑模控制分析 [J]. 液压与气动, 2021, 45(2):123-128.
- XU Hong-tao, LI Yan-min. Sliding mode control analysis of valve-controlled electro-hydraulic servo system based on AMESim and backstepping controller [J]. Hydraulic and Pneumatic, 2021, 45(2):123-128.