

基于双自适应滑动时间窗滚动轴承故障预测模型

郭基联¹, 张保山^{1,2}, 周章文¹, 李波³, 刘晓欣¹

(1. 空军工程大学航空工程学院, 西安, 710038; 2. 91504 部队, 浙江台州, 318050;
3. 93786 部队, 河北张家口, 075000)

摘要 针对传统方法和基于神经网络方法在滚动轴承故障预测中存在的问题, 提出一种双自适应滑动时间窗故障预测模型。首先, 通过设置能够去除相关性的状态估计非线性算子, 将滚动轴承振动信号映射为能够表征其退化状态的故障特征—故障程度指标 DR。其次, 以损失函数为判据, 设置模型参数自适应更新机制, 以及建立能够自适应选取数据长度的滑动时间窗口。最后, 通过西安交通大学发布的滚动轴承全寿命周期数据, 模拟实际中突发性故障和渐发性故障综合作用下的故障发生情况, 验证了所提出的故障预测模型的有效性。实验结果表明, 提出的预测模型能够准确判断滚动轴承退化阶段的开始时刻和故障时刻, 真实反映滚动轴承性能退化的趋势, 预测误差仅为 0.068%, 预测时间仅占 2 次故障间隔时间的 1.385%, 满足复杂工况下滚动轴承故障预测的需求。

关键词 滚动轴承; 故障预测; 滑动时间窗; 自适应

DOI 10.3969/j.issn.2097-1915.2023.04.001

中图分类号 V263 **文献标志码** A **文章编号** 2097-1915(2023)04-0001-07

A Fault Prediction Model for Rolling Bearing Based on Double Adaptive Sliding Time Window

GUO Jilian¹, ZHANG Baoshan^{1,2}, ZHOU Zhangwen¹, LI Bo³, LIU Xiaoxin¹

(1. Aviation Engineering School, Air Force Engineering University, Xi'an 710038, China;
2. Unit 91504, Taizhou 318050, Zhejiang, China; 3. Unit 93786, Zhangjiakou 075000, Hebei, China)

Abstract Traditional and neural network-based methods being in existence of rolling bearing fault prediction, a dual adaptive sliding time window fault prediction model is proposed. Firstly, the rolling bearing vibration signal is mapped into fault features characterized as its degradation state by setting up a state estimation non-linear operator capable of removing correlations. Secondly, taking a loss function as a criterion, an adaptive update mechanism for the model parameters is set up, and a sliding time window capable of adaptively selecting the data length is constructed. Finally, the validity of the proposed failure prediction model is verified by simulating the occurrence of failures under the combined sudden and gradual failures in practice using the whole life cycle data of rolling bearings released by Xi'an Jiaotong University. The experimental results show that the prediction model proposed can accurately identify at the beginning moment and at the failure moment for the rolling bearing at the degradation stage, and truly reflect the trend of equipment performance degradation. The prediction error is only 0.068% and the prediction time

收稿日期: 2022-11-30

作者简介: 郭基联(1971-), 男, 浙江兰溪人, 教授, 博士生导师, 研究方向为飞机可靠性、维修性的论证和评估。E-mail: guojilian@aliyun.com

引用格式: 郭基联, 张保山, 周章文, 等. 基于双自适应滑动时间窗滚动轴承故障预测模型[J]. 空军工程大学学报, 2023, 24(4): 1-7. GUO Jilian, ZHANG Baoshan, ZHOU Zhangwen, et al. A Fault Prediction Model for Rolling Bearing Based on Double Adaptive Sliding Time Window[J]. Journal of Air Force Engineering University, 2023, 24(4): 1-7.

is only 1.385% of the interval between failures, meeting the needs of rolling bearing failure prediction under condition of complex operation.

Key words rolling bearing; fault prediction; sliding time window; adaptive

滚动轴承的主要功能是承受载荷和传递作用力,是现代各类旋转机械广泛使用的零件之一。同一机械中滚动轴承型号众多,使用工况复杂,突发性故障和渐发性故障交织,很难用一种特定的故障模式对其进行界定。滚动轴承一旦发生故障,将会发生较大的振动,严重影响机械的安全性和可靠性。因此,开展具有泛化能力的滚动轴承故障预测研究,对于提高机械的可靠性具有重要的意义^[1-2]。

目前,滚动轴承故障预测模型大致可分为两大类,传统故障预测模型和基于神经网络的故障预测模型。传统故障预测模型能够依据故障机理、结构特征和状态空间等先验知识,建立有效的数学模型,从而实现故障预测,如最小二乘支持向量机(support vector machine, SVM)故障预测模型^[3],高阶模糊时间序列故障预测模型^[4],以及灰色马尔可夫链(grey markov chain, GM)故障预测模型^[5]等。虽然以上传统故障预测方法取得了一定的研究成果,但由于其过于依赖先验知识,大数据处理效率不高,以及数据挖掘能力较差,在突发性故障和渐发性故障交织的复杂工况条件下,难以建立滚动轴承故障预测的数学表达式,故障预测精度往往较低。近些年,神经网络在故障预测领域得到了广泛应用,且取得了良好的预测效果,如递归神经网络(recurrent neural network, RNN)故障预测模型^[6],以及卷积神经网络(convolutional neural network, CNN)故障预测模型^[7]。基于神经网络的故障预测模型虽取得了较好的预测效果,但依然存在适应变化能力差,可解释性不强,数据需求量大,以及全连接模式冗余且低效的缺点,对大型机械多种类型的滚动轴承故障预测效率难以提升。

本文以传统故障预测方法——时间序列预测法(time series forecasting method, TSFM)^[8]为基础,使用神经网络中求极小值的核心算法——梯度下降算法对其数据转折点的鉴别能力,以及平滑因子自适应选择能力进行改进,设计了一种既能自适应更新参数,确保其强大的泛化能力,又能自适应截取故障数据长度,确保其快速反映能力的双自适应故障预测模型。

1 双自适应滑动时间窗故障预测模型

基于双自适应滑动时间窗故障预测模型设计方

法如下:

1.1 故障特征提取

将滚动轴承某 t 时刻的振动信号分解为 n 个相互关联的状态变量,将其记为观测变量 \mathbf{X}_t ,即:

$$\mathbf{X}_t = [x_{t,1}, x_{t,2}, \dots, x_{t,n}]^T \quad (1)$$

式中: $x_{t,n}$ 为 t 时刻状态变量的观测值。

构建具有 m 个历史时刻(振动信号), n 个相互关联状态变量的历史记忆矩阵 \mathbf{D} ,即:

$$\mathbf{D} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m] = \begin{bmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,m} \\ x_{2,1} & x_{2,2} & \dots & x_{2,m} \\ \vdots & \vdots & \dots & \vdots \\ x_{n,1} & x_{n,2} & \dots & x_{n,m} \end{bmatrix}_{n \times m} \quad (2)$$

由历史记忆矩阵 \mathbf{D} 中 m 个输入观测向量 \mathbf{X}_{obs} 的线性加权,可获得估计向量 \mathbf{X}_{est} ,即:

$$\mathbf{X}_{\text{est}} = \mathbf{D}\mathbf{W} = \omega_1 \mathbf{X}_1 + \omega_2 \mathbf{X}_2 \dots \omega_m \mathbf{X}_m \quad (3)$$

式中: $\mathbf{W} = [\omega_1, \omega_2, \dots, \omega_m]^T$ 为一个 m 维的权值向量,代表输入观测向量 \mathbf{X}_{obs} 与历史记忆矩阵 \mathbf{D} 的相似度,即:

$$\mathbf{W} = (\mathbf{D}^T \otimes \mathbf{D})^{-1} (\mathbf{D}^T \otimes \mathbf{X}_{\text{obs}}) \quad (4)$$

式中: \otimes 为非线性运算符,用以代替普通矩阵中的乘积运算,避免 $\mathbf{D}^T \otimes \mathbf{D}$ 所产生的不可逆现象,扩大式的适应范围^[9]。为提升多维数据处理能力,本文将 \mathbf{D}^T 与 \mathbf{X}_{obs} 之间的马氏距离(mahalanobis distance, MD)^[10]作为非线性运算符,即:

$$\otimes (\mathbf{X}, \mathbf{Y}) = \sqrt{(\mathbf{X} - \mathbf{Y})^T \sum^{-1} (\mathbf{X} - \mathbf{Y})} \quad (5)$$

式中: \sum^{-1} 为多维随机变量协方差矩阵的逆矩阵,直观可以看出,当两个状态矩阵越相似时,其 MD 越小;当两个状态矩阵差异性越大时,其非线性运算结果越大。

将式(5)带入式(4)中,可得估计向量的最终表达式为:

$$\mathbf{X}_{\text{est}} = \mathbf{D} (\mathbf{D}^T \otimes \mathbf{D})^{-1} (\mathbf{D}^T \otimes \mathbf{X}_{\text{obs}}) \quad (6)$$

通过对比观测向量 \mathbf{X}_{obs} 与估计向量 \mathbf{X}_{est} 之间的差值,可直观得到反应滚动轴承故障程度的残差值 ϵ ,即:

$$\epsilon = \mathbf{X}_{\text{est}} - \mathbf{X}_{\text{obs}} \quad (7)$$

通过对比各类故障指标的使用范围,本文选用 均方根反映故障程度,如表 1 所示^[10]。

表 1 误差指标表

指标	公式	意义	指标	公式	意义
VARV	$VARV = \frac{1}{N-1} \sum_{i=0}^{N-1} (x_i - \mu)^2$	描述振动信号的波动	E	$E = \sum x_i ^2$	表征故障信号的影响
RMSV	$RMSV = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i ^2}$	振动信号强度	SE	$SE = - \sum_i P(x_i) \log_2 [P(x_i)]$	
SF	$SF = \frac{RMSV}{\frac{1}{N} \sum_{i=0}^{N-1} x_i }$	有效值与矫正均值之比	RE	$RE = \frac{1}{1-\alpha} \log \sum_{i=1}^N P(x_i)^\alpha$	通过有效测量熵值提取轴承故障状态的本质信息
MF	$MF = \frac{\text{Max}(x_i)}{\frac{1}{N} \sum_{i=0}^{N-1} x_i ^2}$	表征机械的磨损程度	TE	$TE = \frac{1}{q-1} (1 - \sum_{i=1}^N P(x_i)^q)$	

式中:VARV 为方差值;RMSV 为均方根值;SF 为形状因子;MF 为边际因子;E 为能量;SE 为香农熵;RE 为仁义熵;TE 为察里斯熵。

通过求 n 个维度 \mathbf{X}_{est} 与 \mathbf{X}_{obs} 残差 ϵ 的 RMSV, 即可得到反应滚动轴承故障程度指标 DR:

$$DR = \sqrt{\frac{1}{m} \sum_{i=1}^m |\epsilon_i|^2} \quad (8)$$

1.2 双自适应滑动时间窗建模

双自适应滑动时间窗建模如下:

$$\begin{cases} S_t^{(1)} = \alpha_{t+T}^i DR_t + (1 - \alpha_{t+T}^i) S_{t-1}^{(1)} \\ S_t^{(2)} = \alpha_{t+T}^i S_t^{(1)} + (1 - \alpha_{t+T}^i) S_{t-1}^{(2)} \end{cases} \quad (9)$$

式中: α_{t+T}^i 为第 $t+T$ 次预测的第 i 次训练自适应平滑因子,以其表示前一时刻 DR_t 对于当前时刻故障预测的重要性; $S_t^{(1)}$ 为一次平滑值, $S_t^{(2)}$ 为二次平滑值,以其表示除前一时刻外,其余时刻对当前故障预测的重要性。

若 T 表示预测时间, DR_{t+T}^i 表示 $t+T$ 时刻第 i 次训练的滚动轴承故障程度的预测值,则其预测公式为:

$$DR_{t+T}^i = f_{t+T}^i(DR_t, \alpha) = A_T + B_T T \quad (10)$$

式中:

$$\begin{cases} A_T = 2S_t^{(1)} - S_t^{(2)} \\ B_T = \left(\frac{\alpha_{t+T}^i}{1 - \alpha_{t+T}^i} \right) (S_t^{(1)} - S_t^{(2)}) \end{cases} \quad (11)$$

通过对比各类梯度下降算法的适用范围,本文

选用随机梯度下降 (stochastic gradient descent, SGD) 自适应更新平滑因子 α_{t+T}^i ,如表 2 所示。

表 2 梯度下降算法对比表

算法	优点	缺点
BGD	易找到全局最优点	不适于大数据和快速更新
SGD	避免数据冗余,收敛速度快	适用于大数据和快速更新
SGDM	能够抑制振荡,加速 SGD	需有可靠的初始参数
AdaGrad	学习率自更改	复杂网络;处理稀疏梯度
AdaDelta	避免参数更新时单位不统一	复杂网络;处理稀疏梯度
Adam	对内存需求小	复杂网络;处理稀疏梯度;高维空间

其中:BGD 为批量梯度下降 (batch gradient descent, BGD); Momentum-SGD 为带动量的随机梯度下降 (stochastic gradient descent momentum, SGDM); AdaGrad 为自适应梯度 (adaptive gradient, AdaGrad); AdaDelta 为自适应德尔塔 (adaptive delta, AdaDelta); Adam 为自适应短估计 (adaptive moment estimation, Adam)。

则第 $t+T$ 次预测的第 i 次训练自适应平滑因子 α_{t+T}^i 的表达式为:

$$\alpha_{t+T}^i = \alpha_{t+T}^{i-1} - \beta (DR_{t+T}^i - DR_{t+T}) \partial J_{t+T}^i(\alpha) \quad (12)$$

式中: α_{t+T}^{i-1} 为第 $t+T$ 次预测的第 $i-1$ 次训练自适

应平滑因子; β 为学习因子, 用于控制自适应 α_{i+T}^{-1} 调整的速率; DR_{i+T}^i 为第 $t+T$ 次预测的第 i 次训练滚动轴承故障程度的预测值; DR_{i+T} 为第 $t+T$ 个滚动轴承故障程度实际值; $\partial J_{i+T}^i(\alpha)$ 为第 $t+T$ 次预测的第 i 次训练损失函数对 α 的偏导。

$$J_{i+T}^i(\alpha) = \frac{1}{2l_{i+T}^i} \sum_{k=1}^{l_{i+T}^i} (DR_{i+T}^i - DR_{i+T})^2 \quad (13)$$

式中: l_{i+T}^i 为第 $t+T$ 次预测的第 i 次训练的滚动轴承故障程度 DR_i 数据长度, 即自适应滑动时间窗 l_{i+T}^i , 如图 1 所示。

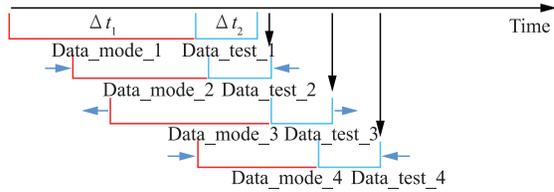


图 1 滑动时间窗示意图

图 1 中 $Data_mode_i$ 是指第 i 次训练的训练数据, $Data_test_i$ 是指第 i 次训练的测试数据, $l_{i+T}^{i-1} = Data_mode_i + Data_test_i$ 。

$$l_{i+T}^i = l_{i+T}^{i-1} \left(1 + \mu \frac{\sum_{k=1}^{l_{i+T}^{i-1}} J_{i+T}^{i-1}(\alpha)}{\sum_{k=1}^{l_{i+T}^{i-1}} |J_{i+T}^{i-1}(\alpha)|} \right) \quad (14)$$

式中: μ 为调整因子, 用于控制自适应滑动时间窗 l_{i+T}^i 调整的速率。

由图 1 和式(14)得, 当滚动轴承故障程度 DR_i 数据量, 不能有效反映故障信息时, 即损失函数的偏导 $\partial J(\alpha)$ 一直为同方向, 则 l_{i+T}^i 应持续增长或减小, 以满足挖掘故障信息的需求, 自适应滑动时间窗 l_{i+T}^i 最大按照 $1 + \mu$ 倍增长或 $1 - \mu$ 倍缩短; 当滚动轴承退化程度 DR_i 数据量能部分反映故障信息时, 即损失函数的偏导 $\partial J(\alpha)$ 不均为同方向, 则 l_{i+T}^i 长度取决于 $\sum_{k=1}^{l_{i+T}^{i-1}} \partial J(\alpha)$ 的方向, 即 $\sum_{k=1}^{l_{i+T}^{i-1}} \partial J(\alpha)$ 为正时, 自适应滑动时间窗 l_{i+T}^i 的数据量增加, $\sum_{k=1}^{l_{i+T}^{i-1}} \partial J(\alpha)$ 为负时, 自适应滑动时间窗 l_{i+T}^i 数据量减少。

本文选用均方误差 MSE 代表最终预测误差。

$$MSE = \frac{1}{N-1} \sum_{i=0}^{N-1} (DR_i^i - DR_i)^2 \quad (15)$$

式中: N 为所有滚动轴承故障程度 DR_i 数据量。为

将训练过程中的故障程度 DR_{i+T}^i 与单次最终所得的预测程度值区分, 本文定义 DR_i^i 为单次故障程度预测所得的最终值, DR_i 为真实值。

2 滚动轴承故障预测方法设计

2.1 难点分析

滚动轴承常用的故障预测数据为具有高度随机性的振动信号数据, 但由于以下原因其振动信号往往呈现出高度的复杂性:

1) 由于突发性故障、性能退化趋势多样性以及故障发展性^[10]等自身内在因素的不同, 同机械的各滚动轴承振动信号呈现出多种类型^[11]。

2) 由于台次差异、装配误差以及使用环境^[12]等自身外在因素的不同, 同机械的各滚动轴承振动信号呈现出多种类型。

3) 由于机械共振、安装位置以及传感器误差等其他外在因素的不同, 同机械的各滚动轴承振动信号呈现出多种类型。

因此, 滚动轴承故障预测的难点在于振动信号噪声干扰大, 故障特征提取较为困难; 出现于早期的渐发性故障振动信号较弱, 难以识别; 随时可能发生的突发性故障振动较强, 但提前预警难度大; 振动信号数据量大, 如何剔除干扰信息, 快速识别出故障时刻较为困难。

2.2 方法设计

本文滚动轴承故障预测设计侧重于以下 3 点:

1) 滚动轴承前期故障信号往往较弱, 故障预测方法需准确提取故障特征信息, 在其发生故障前, 准确预测渐发性故障的发生时刻, 才能为视情维修提供科学依据;

2) 滚动轴承后期故障信号虽然较强, 但此时滚动轴承的健康状态已发生较大变化, 前期故障信号对当下故障预测贡献度较小甚至产生负作用。因此, 本文的故障预测方法需设计科学的故障数据截取机制, 快速筛选有效信息, 准确实现滚动轴承的故障预测;

3) 同机械中滚动轴承规格型号多样, 工作条件多变, 难以按照预测参数对各工况下的滚动轴承进行预测。因此, 故障预测方法需有强大的泛化能力, 自适应更新模型参数, 以保证较高的实用价值。

本文滚动轴承故障预测方法设计如图 2 所示。

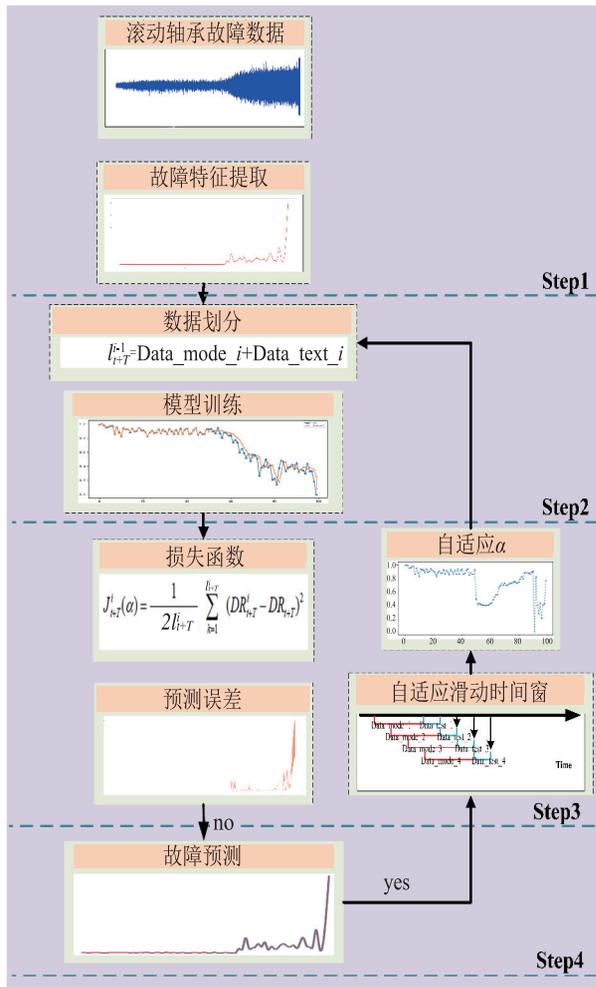


图2 故障预测流程图

步骤1 数据处理,将滚动轴承第 $t+T$ 次振动信号转化成其对应的故障特征,并消除数据之间的相关性,以保证所提取故障特征的正确性;

步骤2 第 $t+T$ 次预测的第 i 次训练,预测模型先将第 $i-1$ 次预设滑动时间窗 $\text{length}_{t+T}^{i-1}$ 划分为第 i 次的训练数据 $\text{Data_mode_}i$ 和测试数据 $\text{Data_test_}i$,将第 $i-1$ 次训练的平滑因子 α_{t+T}^{i-1} 和滑动时间窗 l_{t+T}^i 带入指数平滑中预测第 i 次训练故障程度值 DR_{t+T}^i ,以保证模型能够自适应截取合理的数据长度,以及自适应改变模型参数,确保模型具有强大的泛化能力和适应数据变换的快速收敛能力。

步骤3 用退化程度值 DR_{t+T}^i 计算第 i 次训练的损失函数 $J_{t+T}^i(\alpha)$,若满足最大循环次数或小于最小误差,则停止训练;若不满足上述条件,则根据更新准则自适应更新平滑因子 α_{t+T}^i 和自适应滑动时间窗 l_{t+T}^i ,重复第2步,开始第 $t+T$ 次预测的 $i+1$ 次训练,确保模型能够依据机械故障程度数据,自适应学习,更新模型参数。

步骤4 将步骤3得到的自适应平滑因子 α_{t+T}^i 带入预测公式,求得最终故障程度 DR_{t+T}^i ,并计算预测误差 e 。

3 实验分析

3.1 振动信号分析

本文利用文献[13]发布的滚动轴承性能退化数据进行分析与验证。该轴承疲劳试验台的具体结构如图3所示。

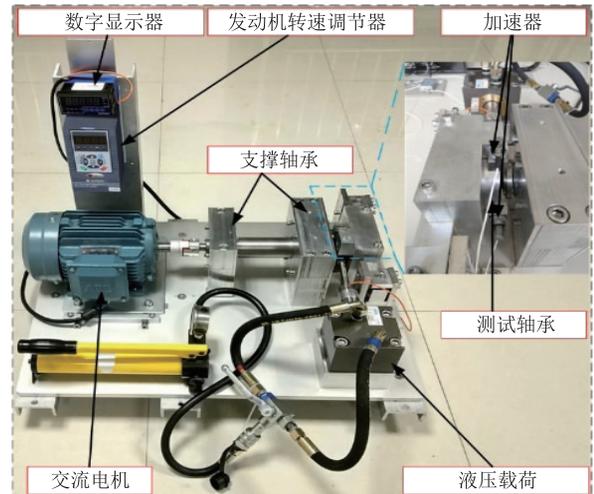


图3 轴承疲劳试验台结构图

为了获得型号为 LDK UER204 的轴承故障数据,将2块 PCB 352C33 加速度计放置在被测轴承的外壳上,彼此之间的夹角为 90° ,即一个放置在横轴,另一个放置在纵轴。设置采样频率为 25.6 kHz/min,径向力为 12 kN,转速为 2 100 rpm,运行 157.44 s。由于载荷是施加在水平方向上的,此方向上的加速度计更能准确反映被测轴承的退化信息。因此,本文选用水平方向上的振动信号反映被测轴承的故障程度,如图4所示。

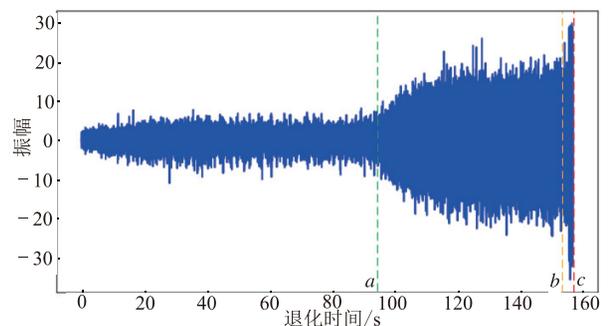


图4 滚动轴承振幅信号图

由图4可知,在轴承性能退化实验前期,振幅变化不大,轴承处于正常退化阶段,即 a 点前;在性能退化实验后期,轴承振幅随工作时间的增加而增大,轴承处于性能退化阶段,即 a 点和 b 点之间;在性能退化实验末期,轴承振幅陡然增大,轴承处于完全失效阶段,即 b 点和 c 点之间。此轴承退化趋势和突变趋势明显,具有一般性和代表性。

因此,本文假定性能下降 20% 即为发生故障,

将滚动轴承全寿命周期数据分为3段,且每一段初始状态滚动轴承的健康程度为100%,即正常退化阶段表征由于滚动轴承性能逐渐劣化而引发的渐发性故障;以性能退化阶段表征不能通过事先的测试或监控预测到的突发性故障;以完全失效阶段表征突发性故障和渐发性故障交织的情况。

因此,是否能准确判断轴承性能退化时刻(突发性故障) a 和完全失效时刻(突发性故障和渐发性故障交织) b ,真实反映轴承退化性能的趋势,保证较高的预测精度和较短的预测时间,是验证本文所提出模型的重点。

3.2 预测结果分析

本文实验硬件:CPU为i7-10875H,运行内存为32GB,显卡为RTX2060,预设自适应滑动时间窗初始值为100,自适应平滑因子 α 初始值为0.05,学习因子 β 为0.5,最大训练迭代次数为1000次,最小允许误差为 10^{-8} 。通过小波阈值去噪算法(wavelet threshold denoising, WTD)对原始滚动轴承振动信号进行处理(此部分非本文的重点研究内容,不多赘述),如图5所示。

将滚动轴承退化数据输入本文所设计的双自适应滑动时间窗模型,则自适应平滑因子 α 变化趋势,自适应滑动时间窗长度变化趋势,以及预测误差 e 变化趋势预测拟合效果分别如图6、7、8、9所示。

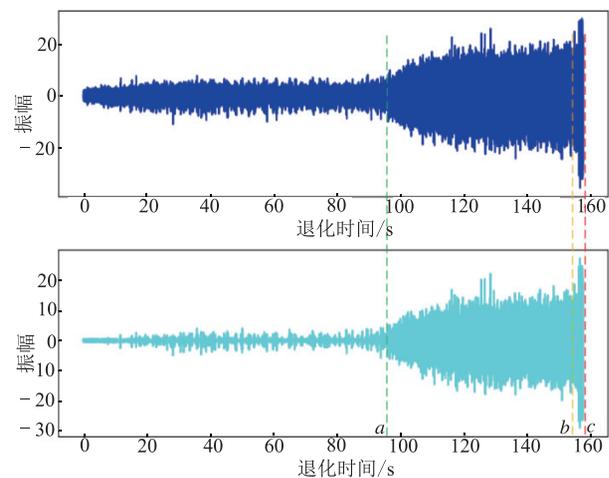


图5 降噪程度变化图

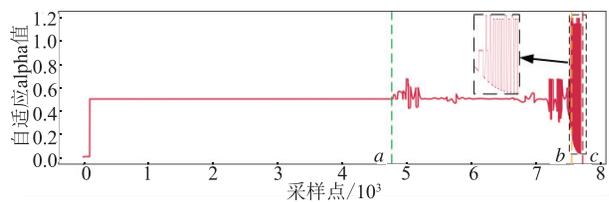


图6 自适应 α 取值变化趋势图

由图6可知,在正常退化阶段,轴承故障程度DR值变化幅度较小,即未发生渐发性故障,此阶段自适应平滑因子 α 除前期短暂调整外,迅速稳定在

0.5左右运行;在性能退化阶段,故障程度DR于 a 至 a' 段突然增大,即发生突发性故障,此阶段自适应平滑因子 α 变化较为明显;在完全失效阶段,滚动轴承振幅于 b 至 b' 段还未发生较大变化,故障程度DR值和自适应平滑因子 α 已经提前开始调整且变化较为剧烈。以上实验表明本文所提出的自适应平滑因子 α 能随着故障程度DR实时变化,准确预判故障发生时刻,寻优能力强,满足故障快速预测的需求。

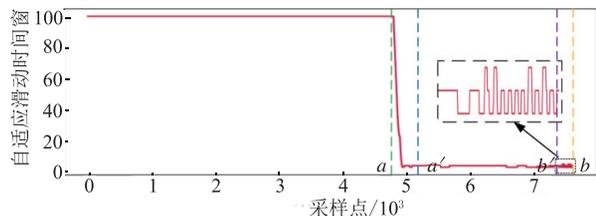


图7 自适应滑动时间窗长度变化趋势图

由图7可知,在正常退化阶段,轴承故障程度DR值变化幅度较小,即未发生渐发性故障,此阶段自适应滑动时间窗稳定在初始值100左右;故障程度DR于 a 至 a' 段突然增大,即发生突发性故障,正常退化阶段的故障数据已不能表征此时滚动轴承的故障程度,甚至产生负效应。因此,自适应滑动时间窗长度迅速缩短;在完全失效阶段,滚动轴承振幅于 b 至 b' 段还未发生较大变化,自适应滑动时间窗已经提前开始小范围波动。以上实验表明本文所提出的自适应滑动时间窗能随着故障程度DR实时变化,在平稳阶段,保持滑动时间窗长度稳定,在变化剧烈阶段,调整滑动时间窗长度迅速,预判故障发生时刻,满足故障快速预测的需求。

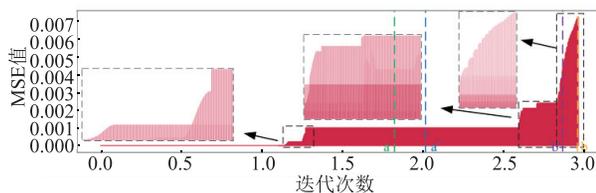


图8 预测误差变化趋势图

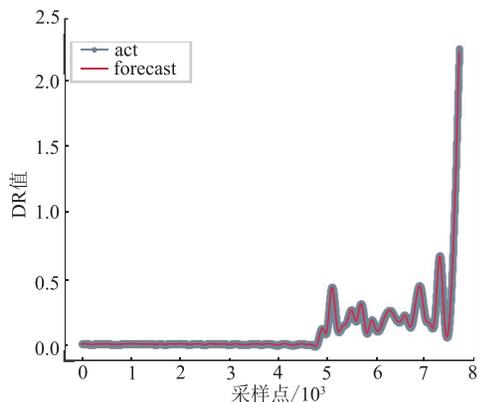


图9 预测拟合效果图

由图8和图9可知,预测误差 e 的变化趋势与滚动轴承故障程度DR的变化趋势相近,即误差随

着故障程度 DR 趋势的复杂程度逐渐增大,到达即将完全失效时刻 b 点误差增大较为明显,符合自适应平滑因子 α 和自适应滑动时间窗的变化趋势,预测值与实际值几乎完全重合,最终预测误差 $e=0.068\%$,拟合精度高,满足故障预测高精度的需求。

此实验条件下,单次平均预测时间约为 0.0277 s ,单次平均预测时间约为 2 次故障程度 DR 间隔时间的 1.385% ,即本文模型能在较短时间内给出滚动轴承故障程度的预测结果,预测时间较短,满足故障预测的需求。

4 结论

针对故障复杂性高、样本数据量少、预测时效性强的滚动轴承故障预测问题,本文提出一种双自适应滑动时间窗故障预测模型,研究结果总结如下:

1)本文提出的自适应参数更新方法,能够克服传统滚动轴承故障预测方法的缺点,自适应设置模型参数,大幅提升 TSFM 算法的数据转折点鉴别能力,能够应用于多种工况下的各型滚动轴承故障预测,泛化能力强,寻优效率高;

2)本文提出的自适应滑动时间窗更新方法,相比神经网络滚动轴承故障预测方法,数据需求量小,物理意义明确,并且能克服随着数据量激增,故障预测时间也逐步递增的缺点,自适应截取故障数据量,实用价值高。

参考文献

- [1] 杨博帆,张琳,张搏,等. 动态多模型指数平滑法融合的在线预测方法[J]. 系统工程与电子技术, 2020, 42(9):2013-2021.
- [2] LING J, LIU G, LI J, et al. Fault Prediction Method for Nuclear Power Machinery Based on Bayesian PP-CA Recurrent Neural Network Model[J]. Nuclear Science and Techniques, 2020, 31(8):75.
- [3] 张振臻, 陈晖, 高玉闪. 基于滑动时间窗主成分分析的液体火箭发动机传感器故障诊断方法[J]. 推进技术, 2022, 43(9):343-353.
- [4] SUN S, ZHOU W, ZHANG M, et al. Fault Analysis of CNC Equipment Based on DEMATEL/ISM/ANP[J]. Journal of Mechanical Science and Technology, 2020, 34(7):1-8.
- [5] CAO J. Misalignment Fault Prediction of Wind Turbines Based on Improved Artificial Fish Swarm Algorithm[J]. Entropy, 2021, 23(6):692.
- [6] ZENG D, LU J, ZHENG Y. Combined Fuzzy Time Series Prediction Method for Fault Prediction of EML Pulse Capacitors[J]. IEEE Transactions on Plasma Science, 2021, 49(2):905-913.
- [7] GUO K, ZHAO J, LIANG Y. Flow Shop Failure Prediction Problem Based on Grey-Markov Model[J]. Personal and Ubiquitous Computing, 2021, 8(1):1-8.
- [8] HUANG W, CHENG J, YANG Y, et al. An Improved Deep Convolutional Neural Network with Multi-Scale Information for Bearing Fault Diagnosis[J]. Neurocomputing, 2019, 359(9):77-92.
- [9] FU X, WANG Y, LI W, et al. Lightweight Fault Detection Strategy for Wireless Sensor Networks Based on Trend Correlation[J]. IEEE Access, 2021(9):9073-9083.
- [10] YANG B, ZHANG L, ZHANG B, et al. Complex Equipment System Resilience: Composition, Measurement and Element Analysis[J]. Reliability Engineering & System Safety, 2022, 228(1): 108783.
- [11] MODARRES M, AMIRI M, JACKSON C. Probabilistic Physics of Failure Approach to Reliability: Modeling, Accelerated Testing, Prognosis and Reliability Assessment [M]. New York: John Wiley & Sons Inc, 2017.
- [12] 严仁章, 文强, 王帅, 等. 拉索加速腐蚀试验及其引起的力学性能退化研究[J]. 土木工程学报, 2023, 56(5):18-31.
- [13] WANG B, LEI Y, LI N, et al. A Hybrid Prognostics Approach for Estimating Remaining Useful Life of Rolling Element Bearings[J]. IEEE Transactions on Reliability, 2018, 69(1):401-412.

(编辑:陈斐)