

# 滚动轴承的退化特征信息融合与剩余寿命预测

张建宇\* 王留震 肖勇 马雅楠

北京工业大学先进制造技术北京市重点实验室,北京,100124

**摘要:**针对滚动轴承剩余寿命预测的需求,提出一种基于稀疏自编码器(SAE)和双向长短期记忆网络(BiLSTM)的预测模型。以滚动轴承全寿命振动数据为研究对象,通过构建反双曲变换的状态退化指标和频域谐波退化因子形成退化指标集,并利用SAE特征融合提取关键特征,消除冗余信息。同时,结合BiLSTM模型捕捉时序特征,实现全周期寿命预测。实验结果表明,所提模型优于支持向量回归、极限学习机、卷积神经网络等模型,预测误差更小,泛化能力更强。

**关键词:**稀疏自编码器特征融合;双向长短期记忆网络预测模型;滚动轴承;反双曲特征指标;频域谐波退化因子

中图分类号:TH182

DOI:10.3969/j.issn.1004-132X.2025.07.018

开放科学(资源服务)标识码(OSID):



## Fusion of Degradation Feature Information and Remaining Life Prediction for Rolling Bearings

ZHANG Jianyu\* WANG Liuzhen XIAO Yong MA Yanan

Beijing Key Laboratory of Advanced Manufacturing Technology, Beijing University of Technology, Beijing, 100124

**Abstract:** To address the demands for remaining life prediction of rolling bearings, a prediction model was proposed based on SAE and BiLSTM network. Taking the full-life vibration data of rolling bearings as research object, a degradation index set was constructed by developing a hyperbolic inverse transformation-based health indicator and a frequency-domain harmonic degradation factor. The SAE was employed for feature fusion to extract key features and eliminate redundant information. Meanwhile, the BiLSTM model was utilized to capture temporal dependencies and achieve full-cycle life prediction. Experimental results demonstrate that the proposed model outperforms support vector regression, extreme learning machines, and convolutional neural networks in terms of smaller prediction errors and stronger generalization capabilities.

**Key words:** sparse autoencoder(SAE) feature fusion; bidirectional long short-term memory(BiLSTM) network predictive model; rolling bearing; inverse hyperbolic characteristic index; frequency domain harmonic degradation factor

### 0 引言

滚动轴承是机械装备的重要支撑部件,其性能对设备的稳定运行至关重要。滚动轴承的剩余寿命预测长期以来是故障诊断领域的研究热点。现有研究表明,有效提取轴承的退化特征是实现寿命预测的关键。然而,特征指标的趋势性与鲁棒性难以兼顾,直接影响预测的精度。

已有研究在特征提取和寿命预测方法上取得了一定进展。WANG等<sup>[1]</sup>采用均方根等时域指标描述退化过程;JIANG等<sup>[2]</sup>采用卷积运算提取时频域特征;ZHANG等<sup>[3]</sup>基于波形熵构造退化特征;WANG等<sup>[4]</sup>将振动信号转换为图像提取退化信息;RAI等<sup>[5]</sup>利用经验模态分解(empirical

mode decomposition, EMD)分析信号;NIKO-LAOU等<sup>[6]</sup>采用小波包变换(wavelet packet transform, WPT)分析信号。然而,上述方法在分析信号的趋势性和敏感性之间存在平衡问题。

模型驱动和数据驱动是寿命预测的主要研究模式。模型驱动依赖精确的数学模型,但难以全面反映复杂工况;数据驱动通过机器学习算法实现预测,表现出较大的灵活性。LI等<sup>[7]</sup>基于退化状态系数进行剩余寿命预测;LI等<sup>[8]</sup>提出融合多种算法的模型来实现剩余寿命预测;CAO等<sup>[9]</sup>利用TCN-RSA进行建模来实现寿命预测;RATAORE等<sup>[10]</sup>采用基于注意力的双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络提高模型的预测能力;WANG等<sup>[11]</sup>提出一种基于多特征融合的Pearson-KPCA

收稿日期:2023-12-18 修回日期:2025-02-17

基金项目:国家自然科学基金(51675009)

模型来预测滚动轴承剩余使用寿命。已有研究通过时域、频域、时频域分析及深度学习方法提取退化特征,并采用模型驱动或数据驱动方法进行寿命预测,提高了预测精度和泛化能力,但在鲁棒性、计算复杂度和平衡趋势性与敏感性方面仍存在挑战。

针对上述问题,本文提出一种结合统计退化指标与频域特征的融合模型。首先,基于反双曲变换函数的单调性构建反双曲变换统计指标。然后,结合故障演变中谐波能量的变化趋势给出频域谐波因子,通过稀疏自动编码器(sparse autoencoder,SAE)融合退化指标集消除冗余信息,并结合 BiLSTM 网络捕捉时序特征,最终实现滚动轴承的全周期寿命预测。

### 1 滚动轴承退化特征指标集的构造

#### 1.1 XJTU-SY 全寿命数据集简介

正常工况下的滚动轴承寿命普遍较长且有发散性。本文研究的试验数据均来自西安交通大学与昇阳科技公司共同完成的滚动轴承加速寿命试验数据集即 XJTU-SY 数据集<sup>[12]</sup>。实验台由交流电机、电动机转速控制器、转轴、支撑轴承、液压加载系统等组成,如图 1 所示。




图 1 XJTU-SY 滚动轴承实验台

Fig.1 XJTU-SY rolling bearing test bench

该实验台在垂直和水平方向安装加速度传感器 PCB 352C33。设置的 3 种运行工况如表 1 所示。实验轴承型号为 LDK UER204。信号采样频率为 25.6 kHz,采样长度为 1.28 s,采样间隔为 1 min(直至轴承部件发生失效)。将每个实验轴承采集的样本数量定义为轴承寿命。工况 C1 对

表 1 LDK UER204 加速寿命试验工况

Tab.1 LDK UER204 accelerated life test condition

工况	电机转速/(r·min <sup>-1</sup> )	径向载荷/kN
C1	2100	12
C2	2250	11
C3	2400	10

应第一个实验轴承即轴承 1-1(寿命为 123 min)采集的 123 个样本,其他轴承依此类推。

#### 1.2 反双曲退化因子的提出

寿命预测模型的精度高度依赖状态退化因子(健康指标)的优劣,其中,均方根(root mean square,RMS)是应用最为广泛的状态监测指标。图 2 中的幅值 RMS 曲线可敏感捕捉轴承状态的变化,如 80 min、120 min 的增大。与 RMS 相比,峰值、峭度、脉冲指标等对冲击过度敏感,单调性、稳定性欠佳,不适合用于滚动轴承的寿命预测。




图 2 轴承 1-1 的全寿命振动波形

Fig.2 Lifetime vibration waveform of bearing 1-1

为弥补 RMS 指标的不足,本文引入满足单调性的反双曲函数,构造新的轴承状态退化因子,如表 2 所示,反双曲正弦函数 arsinh、反双曲余弦函数 arcosh、反双曲正切函数 artanh 的定义域不同,因此首先对各组振动数据进行规范化处理,使数据分布符合相应函数的定义域要求,再代入表 2 中的表达式中获得反双曲变换结果,计算变换后的有效值、方差和标准差并将其作为滚动轴承的状态退化因子。

表 2 反双曲退化因子

Tab.2 Antihyperbolic degeneration factor

函数名称	表达式	定义域	退化因子
arsinh	$\ln(x + \sqrt{x^2 + 1})$	$(-\infty, +\infty)$	有效值、方差、标准差
arcosh	$\ln(x + \sqrt{x^2 - 1})$	$[1, +\infty)$	
artanh	$\frac{1}{2} \ln \frac{1+x}{1-x}$	$(-1, 1)$	

图 3 为轴承 1-1 反双曲变换后的有效值、方差和标准差趋势图,各组曲线均能反映该轴承的状态退化过程,都在第 80 min、120 min 发生突变。为定量评估反双曲函数退化因子的性能,计算归一化的指标,以及归一化的有效值的余弦相似度:

$$\cos \theta_i = \frac{\mathbf{P}_1 \cdot \mathbf{P}_i}{\|\mathbf{P}_1\| \|\mathbf{P}_i\|} \quad (1)$$

式中: $\mathbf{P}_1$  为归一化处理后的均方根特征值向量; $\mathbf{P}_i$  为归一化处理后的其他特征指标值向量, $i = 2, \dots, 9$ 。

通过计算特征值之间的余弦相似度,定量评估不同退化因子的性能。




图3 轴承 1-1 的反双曲退化因子

Fig.3 Inverse hyperbolic degradation factor of bearing 1-1

如表 3 所示,反双曲退化因子具备良好的单调性和稳定性,与全寿命周期的 RMS 曲线强相关,对滚动轴承剩余寿命预测的准确性有显著影响。

表 3 反双曲退化因子与有效值的余弦相似度

Tab.3 Cosine similarity between the inverse hyperbolic degradation factor and the RMS value

函数	有效值	标准差	方差
arsinh	0.86	0.94	0.86
arcosh	0.85	1.00	0.98
artanh	0.85	0.99	0.88

### 1.3 频域谐波退化因子的构造

滚动轴承在状态退化过程中,时域信号能量发生变化,引发频域结构的显著变化。图 4 为 XJTU-SY 数据集轴承 1-1(工况 C1)、2-1(工况 C2)的包络频谱瀑布图,其中,轴承 1-1 的最终失效位置为外圈,轴承 2-1 的最终失效位置为内圈。

轴承 1-1 的寿命为 123 min。如图 4a 所示,第 10、30、50 min 的频域能量较低,没有明显的频域变化;从第 80 min 开始,包络谱出现明显的谐波特征,频域能量较高,基频 108 Hz 为该轴承的外圈故障频率  $f_o$ ,这与图 2、图 3 中的第一个突变位置相吻合。对比图 4a 中第 98 min 和 110 min

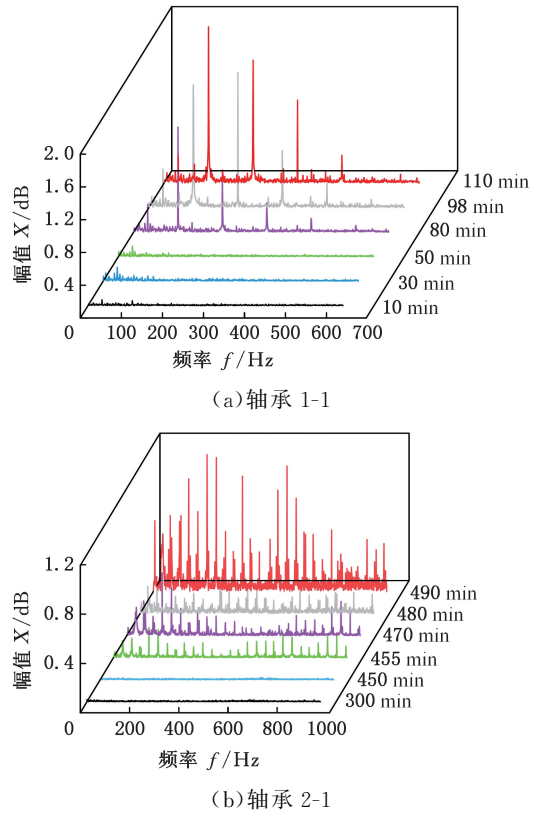


图 4 滚动轴承的包络谱瀑布图

Fig.4 Envelope spectrum waterfall diagram of rolling bearing

的曲线可知,随着轴承状态的持续退化,外圈故障频率  $f_o$  的谐波能量越来越突出。


轴承 2-1 的寿命为 491 min。图 4b 所示为 300~491 min 的典型包络谱,第 300、450 min 的频域能量很低;从第 455 min 开始出现明显的谐波特征,随着轴承状态的进一步劣化(第 470、480、490 min),轴承的内圈故障频率  $f_i$  及其谐波能量愈发突出,围绕  $f_i$  各阶谐波的转频边带的能量也越来越强。

根据滚动轴承频域能量的演变,本文通过构造频域谐波退化因子(frequency-domain harmonic degradation indicator, FHDI)来跟踪轴承状态的退化过程,具体方法如下:


1) 计算滚动轴承的各阶故障特征频率,主要考虑外圈、内圈、滚动体故障来计算故障特征频率,外圈、内圈、滚动体故障对应的特征频率分别为  $f_o$ 、 $f_i$ 、 $f_e$ 。

2) 计算滚动轴承各组样本振动信号的包络解调谱。

3) 围绕理论故障特征频率的第  $h$  阶谐波( $h$  最大值取 5),为捕捉故障特征频率的能量特征,在谐波频率  $f_h$  附近建立一定宽度的频窗。频窗的左右边界分别用  $A_h$ 、 $B_h$  表示,频窗范围的划分、频窗与对应谐波的关系如图 5 所示。



(a) 轴承 1-1 第 80 min 的包络谱



(b) 轴承 2-1 第 455 min 的包络谱

图 5 FHDI 退化因子的构造原理

Fig.5 Construction principle of FHDI degradation factor

图 5a 中,红框为围绕故障频率设置的频窗,频窗边界的计算公式为

$$\left. \begin{aligned} A_o &= (h - W)f_o \\ B_o &= (h + W)f_o \end{aligned} \right\} \quad (2)$$

式中:W 为频窗的宽度系数。

图 5b 对应的谐波频窗边界定义如下:

$$\left. \begin{aligned} A_i &= hf_i - 3f_n \\ B_i &= hf_i + 3f_n \end{aligned} \right\} \quad (3)$$

式中: $f_n$  为内圈转频, $h = 1, 2, \dots, 5$ 。

为捕捉频带中丰富的边带信息,内圈故障谐波频窗的宽度应为  $6f_n$ 。类似地,滚动体故障的谐波频窗边界为

$$\left. \begin{aligned} A_e &= hf_e - 3f_c \\ B_e &= hf_e + 3f_c \end{aligned} \right\} \quad (4)$$

式中: $f_c$  为保持架旋转频率。

为避免谐波频窗出现重叠,本文设置  $W = 0.3$ 。

各阶谐波频窗的能量有效值为

$$R_a = \frac{1}{5} \sum_{h=1}^5 \sqrt{\frac{1}{N} \sum_{\Lambda_h}^{B_h} y^2(n)} \quad a = o, i, e \quad (5)$$

式中:N 为频窗内的数据点数; $y(n)$  为频窗内第  $n$  个采样点的振幅值; $n$  为采样点的索引号。

$R_a$  为第  $h$  阶谐波对应的频窗口内的信号能量之和,计算方式是对窗口范围内的所有采样点振幅平方求和,即在频率范围内进行求和。

4) 参照式(5),计算内圈和滚动体的谐波频窗能量,进而按照

$$F = \frac{1}{3}(R_o + R_i + R_e) \quad (6)$$

计算 3 组谐波频窗能量的均值即滚动轴承全寿命周期的状态退化因子。绘制轴承 1-1 整个寿命周期的 FHDI 趋势图(图 6)。




图 6 轴承 1-1 的 FHDI 因子趋势图

Fig.6 FHDI factor trend chart of bearing 1-1

通过计算,轴承的频域谐波退化因子(FHDI)与有效值(RMS)的余弦相似度为 0.86。FHDI 能清晰跟踪滚动轴承的状态退化过程,并与 RMS 呈现较强的相关性。

## 2 基于 SAE-BiLSTM 的寿命预测模型

### 2.1 基于 SAE 的特征融合模型

由图 3、图 6 可知,反双曲变换统计值和 FHDI 均能敏感捕捉滚动轴承的状态退化且特征趋势相近,但这些特征所含信息过度冗余,因此有必要对特征指标(反双曲变换统计值和 FHDI)进行降维处理。

自编码器(autoencoder, AE)可实现数据压缩、特征融合,包括输入层、隐藏层和输出层。AE 通过控制输出层与输入层之间的重构误差实现自编码器优化。

本文构造的稀疏自编码器在传统编码-解码的基础上,引入稀疏性约束项即 KL 散度(度量隐层激活值的期望分布  $P(i)$  和实际分布  $Q(i)$  的相似性)

$$D_{KL}(P \parallel Q) = \sum_i P(i) \ln \frac{P(i)}{Q(i)} \quad (7)$$

式中: $i$  表示隐层节点索引。

作为稀疏惩罚项,提高隐藏层的压缩性能。

采用稀疏自编码器实现退化特征指标集的降维步骤如下:

1) 指标集构造。按照 1.2 节、1.3 节的方法,对滚动轴承样本集中的每组信号计算反双曲变换的统计值和频域谐波能量因子,并将这两类特征组合成多维特征向量。对特征向量的每一列都进行归一化预处理,以作为模型的输入向量。

2) 特征集的信息融合。建立 10-2-10 的全连接自编码器网络模型,其中,输入层的 10 个节点对应轴承的 10 特征指标,隐层层包含 2 个单元,

输出层的 10 个单元对应 10 个输入特征。模型的损失函数定义为编码层输出与解码层重构输出之间的均方误差 (mean squared error, MSE), 引入稀疏性约束项强化隐含层的稀疏特性。网络权重和偏置的优化采用 Adam 算法, 以最小化损失函数为目标。

3) 在稀疏编码器训练稳定后, 提取模型的 2 维隐含层参数并作为融合后的特征指标, 用于后续的使用寿命预测。图 7 为轴承 1-1 经 SAE 降维后得到的 2 个融合指标趋势图。单调性和平滑性有助于捕捉数据的运行趋势和内在模式, 提高模型的泛化能力和预测精度。




图 7 轴承 1-1 的降维后特征曲线图

Fig.7 Characteristic curves of bearing 1-1 after dimensionality reduction

## 2.2 基于 BiLSTM 的使用寿命预测框架

如图 8 所示, BiLSTM 神经网络<sup>[13]</sup>由正逆双向循环的 2 个长短期记忆 (long short term memory, LSTM) 模型<sup>[14]</sup>组成。BiLSTM 模型的每个 LSTM 单元基本结构与图 8 蓝框所示的结构一致, 包括遗忘门、输入门和输出门。

遗忘门控制上一时刻的细胞状态  $C_{t-1}$  在当前时刻细胞状态  $C_t$  中的保留比例, 控制因子由遗忘门的激活值决定, 计算公式如下:

$$f(t) = \sigma(W_f H_{t-1} + U_f x_t + b_f) \quad (8)$$

式中:  $\sigma(*)$  为 Sigmoid 激活函数;  $W_f$  为遗忘门中  $t-1$  时刻的隐层状态值  $H_{t-1}$  的权重系数;  $U_f$  为遗忘门中  $t$  时刻的输入  $x_t$  的权重系数;  $b_f$  为遗忘门的偏置值。

计算输入门  $i(t)$ 、临时记忆状态信息  $a(t)$ 、计算输出门  $o(t)$  分别为

$$i(t) = \sigma(W_i H_{t-1} + U_i x_t + b_i) \quad (9)$$

$$a(t) = \tanh(W_a H_{t-1} + U_a x_t + b_a) \quad (10)$$

$$o(t) = \sigma(W_o H_{t-1} + U_o x_t + b_o) \quad (11)$$

式中:  $W_i$ 、 $W_o$ 、 $W_a$  分别为输入门、输出门和特征提取过程中  $H_{t-1}$  的权重系数;  $U_i$ 、 $U_o$ 、 $U_a$  分别为输入门、输出门和特征提取过程中  $x_t$  的权重系数;  $b_i$ 、 $b_o$ 、 $b_a$  分别为输入门、输出门和特征提取过程中的偏置值。

遗忘门和输入门计算的结果共同作用于上一时刻的细胞状态  $C_{t-1}$ , 通过下面的公式来更新为当前时刻的细胞状态  $C_t$ :

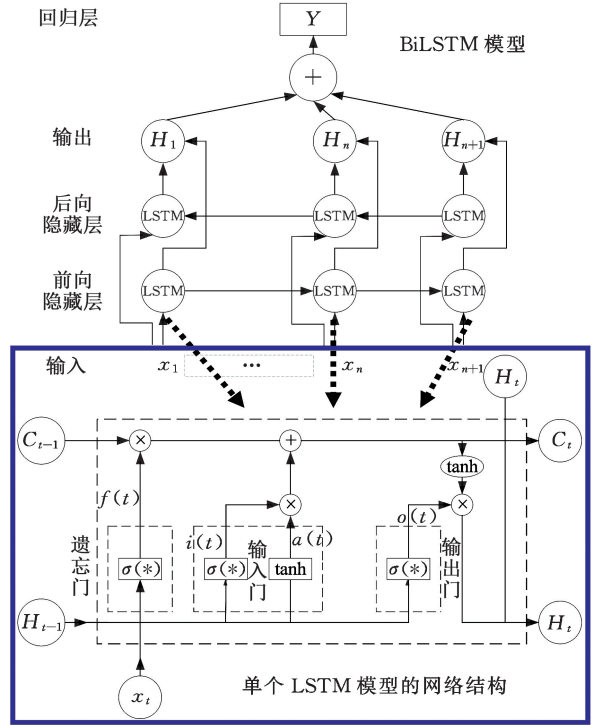


图 8 BiLSTM 网络原理图

Fig.8 BiLSTM network schematic

$$C_t = C_{t-1} \odot f(t) + i(t) \odot a(t) \quad (12)$$

式中:  $\odot$  表示 Hadamard 积。

从而决定当前神经元的状态演化。最终,  $t$  时刻的隐藏层状态  $H_t$  由输出门  $o(t)$  和当前时刻的神经元状态  $C_t$  求出:

$$H_t = o(t) \odot \tanh C_t \quad (13)$$

将输入层的特征向量  $x_t$  输入到 BiLSTM 神经网络模型进行训练。模型由前向和后向两个序列组成, 分别用于处理时间序列的正向特征  $\vec{H}_t$  和反向特征  $\overleftarrow{H}_t$ :

$$\vec{H}_t = \sigma(W_{hx} x_t + W_{hh} \vec{H}_{t-1} + b_h) \quad (14)$$

$$\overleftarrow{H}_t = \sigma(W_{hx} x_t + W_{hh} \overleftarrow{H}_{t+1} + b_h) \quad (15)$$

式中:  $x_t$  为时刻  $t$  输入特征向量;  $W_{hx}$ 、 $W_{hh}$  分别为输入到隐藏层和隐藏层间的权重矩阵;  $b_h$  为偏置向量。

激活函数  $\sigma(*)$  用于引入非线性特性。输出前向特征  $\vec{H}_t$  和后向特征  $\overleftarrow{H}_t$ :

$$\vec{H}_t = (\vec{H}_1, \vec{H}_2, \dots, \vec{H}_m) \quad (16)$$

$$\overleftarrow{H}_t = (\overleftarrow{H}_1, \overleftarrow{H}_2, \dots, \overleftarrow{H}_m) \quad (17)$$

式中:  $m$  为输入序列的总长度, 即时间步的数量。

双向 LSTM 神经网络的输出为

$$y_t = \sigma(W_{y\vec{H}} \vec{H}_t + W_{y\overleftarrow{H}} \overleftarrow{H}_t + b_y) \quad (18)$$

由此可见, 前向 LSTM 依次提取正序特征, 得到  $\vec{H}_t$ ; 后向 LSTM 依次提取时间序列的逆序特征, 得到  $\overleftarrow{H}_t$ 。输出层通过拼接  $\vec{H}_t$  和  $\overleftarrow{H}_t$  得到更全面的特征表示。BiLSTM 模型能同时捕捉时间序列的前后依赖关系, 使得任意时刻的特征信息不

仅依赖于过去的状态,也能参考未来的趋势。对于滚动轴承的全寿命周期预测,相邻时刻的状态信息相关性很高,BiLSTM 的模型结构有助于提高寿命预测的精度。

本文建立的 SAE-BiLSTM 寿命预测模型的运行步骤如下:

1) 构造训练集与测试集。选择一组滚动轴承的全寿命数据作为训练集,根据寿命状态为每个样本分配对应的标签;选取另一组全寿命数据作为测试集,并预先为测试样本分配相应的标签。

2) 数据预处理。按照 2.1 节的分析步骤完成训练集与测试集的特征构造和 SAE 特征融合,即把每组时序样本压缩为 2 维输入向量。

3) 搭建 SAE-BiLSTM 预测模型,该模型由 3 层 BiLSTM 层、ReLU 激活层、1 层全连接层和 1 层回归层组成。输入层单元数量与滚动轴承的寿命周期对应,BiLSTM 采用双向结构。利用训练集完成模型训练,将回归标签与预测标签的均方根误差作为损失函数,通过 Adam 算法完成模型优化。

4) 滚动轴承的寿命预测。利用预选的测试集验证模型的预测结果,按照模型输出预测值  $\hat{y}_i$  与已知标签  $y_i$  的平均绝对误差  $E_{AE}$  和均方根误差  $E_{RMSE}$  定量评价模型的预测性能:

$$E_{AE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (19)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (20)$$

### 3 寿命预测结果分析

XJTU-SY 数据集包含 15 组加速寿命试验结果,其中,轴承 1-5、2-4、3-5 的寿命明显偏离同一工况下的寿命分布特征,轴承 3-1、3-2 呈现典型的突发失效特征,因此排除上述 5 个轴承的数据集。剩余的 10 组数据集中,轴承 1-1 的全寿命数据作为训练集。为验证 SAE-BiLSTM 模型的普适性,测试集的选取策略如下。

1) 轴承 1-3:与训练集(轴承 1-1)处于相同工况(C1),且故障类型相同(外圈失效),用于验证模型在相同工况、相同失效模式下的泛化能力。

2) 轴承 2-2:与训练集的故障类型相同(外圈失效),但工况不同(C2),用于评估模型在不同工况下的适应性。

3) 轴承 3-3:与训练集的工况不同(C3),且故障类型不同(内圈失效),用于考察模型在同时变

化工况和故障模式时的预测能力。


本文选用的候选数据集基本信息如表 4 所示。

表 4 候选数据集的基本信息

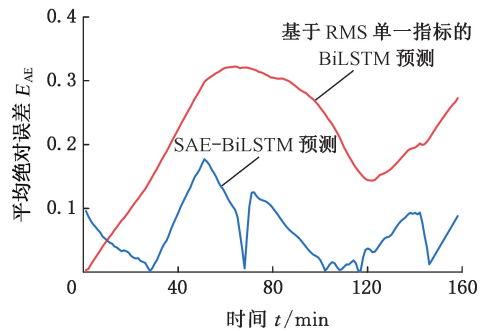
Tab.4 Basic information of selected datasets

轴承代号	工况名称	样本数量	失效位置
1-1	C1	123	外圈
1-3	C1	158	外圈
2-2	C2	161	外圈
3-3	C3	371	内圈

为表明本文融合特征的研究价值,首先对比传统 RMS 的预测结果与 SAE 降维指标的结果,如图 9 所示。



(a) 寿命预测结果



(b) 预测误差曲线

图 9 轴承 1-3 的预测结果


Fig.9 Predicted results of bearings 1-3

由图 9 可见,SAE 融合后的健康指标与真实寿命的拟合程度显著优于单一 RMS 指标。SAE-BiLSTM 模型的  $E_{MAE}$ 、 $E_{RMSE}$  分别为 0.063 83 和 0.077 49,RMS-BiLSTM 模型的  $E_{MAE}$  和  $E_{RMSE}$  分别为 0.2112 和 0.2876,说明 SAE 融合指标的预测误差更小,验证了本文方法在预测精度上的优势。


为说明 SAE-BiLSTM 模型的预测性能,将轴承 1-3、2-2、3-3 的预测结果与 SVR、ELM、CNN、LSTM 等机器学习模型加以对比。

图 10 所示为轴承 1-3 的预测结果。相对于 SVR、ELM、CNN、LSTM 等预测模型,本文模型在寿命中后期与真实值的拟合程度更高。这是因为滚动轴承在试验初期处于健康状态,各模型的

预测效果差异不明显,因此 SAE-BiLSTM 在这一阶段并无显著优势。从轴承 1-3 的 RMS 变化趋势可以看出,RMS 在 60 min 后开始显著上升,表明轴承进入性能退化阶段。SAE-BiLSTM 在 60 min 后的拟合效果显著提升,与 RMS 变化趋势相吻合,这表明 SAE-BiLSTM 能更好捕捉轴承寿命后期的退化特征,提高预测精度。



(a) 寿命预测结果



(b) 预测误差曲线

图 10 轴承 1-3 的预测结果

Fig.10 Predicted results of bearings 1-3

与本文模型相比,支持向量回归和卷积神经网络在退化点(60 min)后表现出相似的预测性能;长短期记忆网络在状态退化中间阶段(60~80 min)的预测效果较好,但在 140 min 后的性能有所下降;极限学习机在整个寿命周期内的预测效果均不理想。

如表 5 所示,SAE-BiLSTM 预测的 MAE、RMSE 分别为 0.077 49 和 0.063 83,为各组模型的最小值。与 SVR、ELM、CNN、LSTM 相比,SAE-BiLSTM 的  $E_{RMSE}$  分别减少 36.51%、59.72%、42.02%、56.90%, $E_{MAE}$  分别减小 42.16%、62.54%、48.76%、52.57%。SAE-BiLSTM 同时

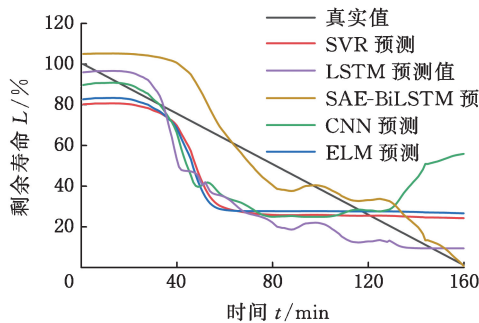
表 5 轴承 1-3 预测结果的误差统计

Tab.5 Error statistics of bearing 1-3 prediction results


模型	$E_{MAE}$	$E_{RMSE}$
SVR	0.110 31	0.121 95
ELM	0.170 34	0.192 28
CNN	0.124 56	0.133 57
LSTM	0.134 53	0.179 65
SAE-BiLSTM	0.063 83	0.077 49

考虑正逆向的时序相关性,在相同工况的寿命预测中取得相对好的效果。

从轴承 2-2 的均方根误差变化(见图 1)可发现振动能量在 40~60 min 明显增大。从图 11 中可以看出,自第 50 min 起,SAE-BiLSTM 的预测精度显著小于其他模型。中段(60~80 min)后,不同模型表现出明显的性能差异,其中,LSTM 在中后段(120~160 min)优于 SVR 和 ELM,CNN 的表现最差。



(a) 寿命预测结果



(b) 预测误差曲线

图 11 轴承 2-2 的预测结果

Fig.11 Predicted results of bearings 2-2

表 6 所示为轴承 2-2 寿命预测结果的误差统计,SAE-BiLSTM 的  $E_{RMSE}$ 、 $E_{MAE}$  分别为 0.118 10 和 0.093 74,在所有模型中最小。与 SVR、ELM、CNN、LSTM 相比,SAE-BiLSTM 的预测  $E_{RMSE}$  分别减小 49.44%、35.00%、33.99%、54.53%, $E_{AE}$  减小 48.26%、37.91%、38.01%、37.74%,在外圈失效的跨工况预测中也取得比较好的效果。

表 6 轴承 2-2 预测结果的误差统计

Tab.6 Error statistics of bearing 2-2 prediction results

模型	$E_{MAE}$	$E_{RMSE}$
SVR	0.181 11	0.233 60
ELM	0.150 98	0.181 76
CNN	0.151 08	0.178 94
LSTM	0.150 52	0.182 51
SAE-BiLSTM	0.093 74	0.118 10

从图 12 中可以看出,在轴承 3-3 寿命的前期(0~340 min),各模型的预测结果较为接近;340 min 之后,轴承状态发生突变,预测结果的差异逐渐显现。相比其他模型,SAE-BiLSTM 在状态突

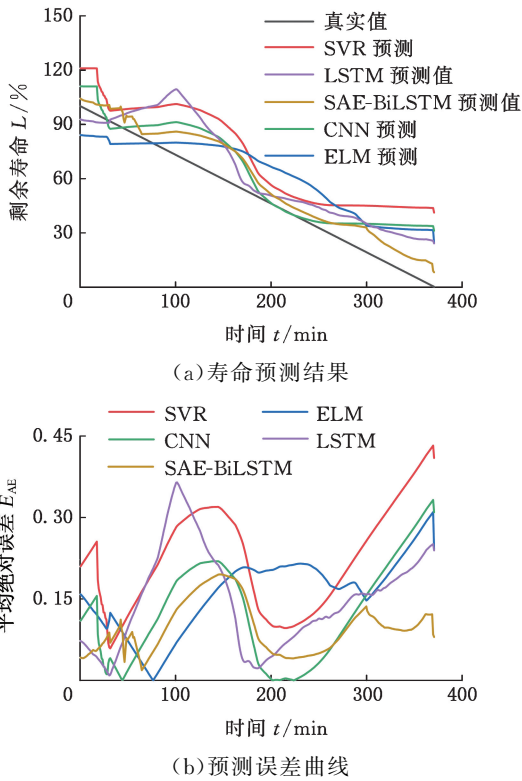


图 12 轴承 3-3 的预测结果

Fig.12 Predicted results of bearings 3-3

变阶段表现出更高的预测精度。

如表 7 所示,轴承 3-3 的预测误差相较于轴承 1-3(表 5)和轴承 2-2(表 6)有所增大,这可能与轴承失效位置的差异有关(轴承 1-1、1-3、2-2 均为外圈失效,轴承 3-3 为内圈失效)。与其他对照模型相比,SAE-BiLSTM 在预测精度上仍表现出显著优势。SAE-BiLSTM 的  $E_{RMSE}$  比 SVR、ELM、CNN、LSTM 分别减小 55.62%、37.90%、30.85%、37.94%, $E_{MAE}$  分别减小 56.58%、39.22%、22.77%、34.90%。

表 7 轴承 3-3 预测结果的误差统计

Tab.7 Error statistics of bearing 3-3 prediction results

模型名称	$E_{MAE}$	$E_{RMSE}$
SVR	0.223 46	0.242 90
ELM	0.159 65	0.173 68
CNN	0.125 62	0.155 90
LSTM	0.149 01	0.173 70
SAE-BiLSTM	0.097 01	0.107 85

## 4 结论

1) 依据反双曲函数自身的单调性特征,创建了反双曲变换统计指标;根据信号频率结构随轴承状态的演变过程,建立了反映退化程度的频域谐波因子。分析结果表明,反双曲变换统计指标和频域谐波因子的变化趋势与 RMS 曲线一致,对应余弦相似度超过 85%,表明这两个指标在表

征轴承退化过程中具有良好的单调性和趋势性。

2) 为剔除退化特征指标集之间的冗余信息,搭建了由全连接神经网络组成的稀疏自编码器特征融合模型,将特征指标集由 10 维降为 2 维;建立了包含正逆向输入的长短期记忆模型,并将其与 SAE 降维模型相结合,实现了滚动轴承的全周期寿命预测。

3) 以某轴承数据集为基础,将 1 个轴承的全寿命数据作为训练集,将 3 个轴承的全寿命数据作为测试集,完成了滚动轴承的剩余寿命预测。尽管 SAE-BiLSTM 模型在不同工况下的预测精度所差异,但与支持向量回归(SVR)、极限学习机(ELM)、卷积神经网络(CNN)、长短期记忆网络(LSTM)等模型相比,SAE-BiLSTM 模型具有更小的预测误差、更高的预测精度、较强的泛化能力。

## 参考文献:

- [1] WANG Gang, XIANG Jiawei. Remain Useful Life Prediction of Rolling Bearings Based on Exponential Model Optimized by Gradient Method[J]. Measurement, 2021, 176:109161.
- [2] JIANG Li, ZHANG Tianao, LEI Wei, et al. A New Convolutional Dual-channel Transformer Network with Time Window Concatenation for Remaining Useful Life Prediction of Rolling Bearings[J]. Advanced Engineering Informatics, 2023, 56: 101966.
- [3] ZHANG Bin, ZHANG Shaohui, LI Weihua. Bearing Performance Degradation Assessment Using Long Short-term Memory Recurrent Network[J]. Computers in Industry, 2019, 106:14-29.
- [4] WANG Biao, LEI Yaguo, LI Naipeng, et al. Deep Separable Convolutional Network for Remaining Useful Life Prediction of Machinery[J]. Mechanical Systems and Signal Processing, 2019, 134:106330.
- [5] RAI A, UPADHYAY S H. Bearing Performance Degradation Assessment Based on a Combination of Empirical Mode Decomposition and K-medoids Clustering[J]. Mechanical Systems and Signal Processing, 2017, 93:16-29.
- [6] NIKOLAOU N G, ANTONIADIS I A. Rolling Element Bearing Fault Diagnosis Using Wavelet Packets[J]. NDT & E International, 2002, 35(3):197-205.
- [7] LI Qiang, YAN Changfeng, CHEN Guangyi, et al. Remaining Useful Life Prediction of Rolling Bearings Based on Risk Assessment and Degradation State Coefficient[J]. ISA Transactions, 2022, 129:

413-428.

- [8] LI Lele, XU Jiawang, LI Juguang. Estimating Remaining Useful Life of Rotating Machinery Using Relevance Vector Machine and Deep Learning Network[J]. Engineering Failure Analysis, 2023, 146: 107125.
- [9] CAO Yudong, DING Yifei, JIA Minping, et al. A Novel Temporal Convolutional Network with Residual Self-attention Mechanism for Remaining Useful Life Prediction of Rolling Bearings[J]. Reliability Engineering & System Safety, 2021, 215:107813.
- [10] RATHORE M S, HARSHA S P. An Attention-based Stacked BiLSTM Framework for Predicting Remaining Useful Life of Rolling Bearings[J]. Applied Soft Computing, 2022, 131:109765.
- [11] WANG Yaping, ZHAO Jiajun, YANG Chaonan, et al. Remaining Useful Life Prediction of Rolling Bearings Based on Pearson Correlation-KPCA Multi-feature Fusion [J]. Measurement, 2022, 201:111572.
- [12] 雷亚国, 韩天宇, 王彪, 等. 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):1-6.
- LEI Yaguo, HAN Tianyu, WANG Biao, et al.

XJTU-SY Rolling Element Bearing Accelerated Life Test Datasets; a Tutorial[J]. Journal of Mechanical Engineering, 2019, 55(16):1-6.

- [13] HU Likun, HE Xujie, YIN Linfei. Remaining Useful Life Prediction Method Combining the Life Variation Laws of Aero-turbofan Engine and Auto-expandable Cascaded LSTM Model [J]. Applied Soft Computing, 2023, 147:110836.
- [14] HOCHREITER S, SCHMIDHUBER J. Long Short-term Memory [J]. Neural Computation, 1997, 9(8):1735-1780.

(编辑 张洋)

作者简介:张建宇\*,男,1975年生,副教授。研究方向为机电设备故障诊断、系统结构动力学分析。发表论文50余篇。E-mail: zhjy\_1999@bjut.edu.cn.

#### 本文引用格式:

张建宇,王留震,肖勇,等.滚动轴承的退化特征信息融合与剩余寿命预测[J].中国机械工程,2025,36(7):1553-1561.

ZHANG Jianyu, WANG Liuzhen, XIAO Yong, et al. Fusion of Degradation Feature Information and Remaining Life Prediction for Rolling Bearings[J]. China Mechanical Engineering, 2025, 36(7):1553-1561.

(上接第1429页)

- [32] BRANDON S, HAIMOVICH N, YEGER E, et al. Partial Wetting of Chemically Patterned Surfaces: the Effect of Drop Size[J]. Journal of Colloid and Interface Science, 2003, 263(1):237-243.
- [33] 李元可,魏昕,汪永超,等.皮秒激光加工工艺对微沟槽表面的疏水性研究[J].激光技术,2022,46(3):301-306.
- LI Yuanke, WEI Xin, WANG Yongchao, et al. Study on Hydrophobicity of Micro-groove Surface by Picosecond Laser Processing[J]. Laser Technology, 2022, 46(3):301-306.
- [34] 郭永刚,吴云飞,朱东坡,等.织构几何参数对超疏水钛合金表面润湿性的影响[J].表面技术,2024,53(22):180-190.
- GUO Yonggang, WU Yunfei, ZHU Dongpo, et al. Effect of Texture Geometric Parameters on Wettability of Superhydrophobic Titanium Alloy Surface[J]. Surface Technology, 2024, 53(22): 180-190.
- [35] 曹祥康,孙晓光,蔡光义,等.耐久型超疏水表面:理论模型、制备策略和评价方法[J].化学进展,

2021, 33(9):1525-1537.

CAO Xiangkang, SUN Xiaoguang, CAI Guangyi, et al. Durable Superhydrophobic Surfaces: Theoretical Models, Preparation Strategies, and Evaluation Methods[J]. Progress in Chemistry, 2021, 33(9):1525-1537.

(编辑 张洋)

作者简介:倪敬,男,1979年生,教授、博士研究生导师。研究方向为集成电路、航空航天与核电风电装备制造工艺、人工智能化(加工与装配精准建模、精确设计和精密调控)。发表论文120余篇。E-mail:nj2000@hdu.edu.cn. 蒙臻\*(通信作者),男,1986年生,副教授、硕士研究生导师。研究方向为航空材料及核心构件的高性能制造、制造过程建模仿真、制造过程监测调控。发表论文20余篇。E-mail:mengzhen@hdu.edu.cn.

#### 本文引用格式:

倪敬,卢蝶,蒙臻,等.激光创成微结构几何精度与润湿性能的关键机制[J].中国机械工程,2025,36(7):1423-1429.

NI Jing, LU Die, MENG Zhen, et al. Correlation Mechanism between Geometric Accuracy and Wettability Performance of Laser-induced Micro-structures [J]. China Mechanical Engineering, 2025, 36(7):1423-1429.