



DOI:10.12404/j.issn.1671-1815.2402488

引用格式:张永超,刘嵩寿,陈昱锡,等.基于 ASFF-AAKR 和 CNN-BILSTM 滚动轴承寿命预测[J].科学技术与工程,2025,25(2):567-573.

Zhang Yongchao, Liu Songshou, Chen Yuxi, et al. Life prediction based on ASFF-AAKR and CNN-BILSTM rolling bearings[J]. Science Technology and Engineering, 2025, 25(2): 567-573.

机械、仪表工业

# 基于 ASFF-AAKR 和 CNN-BILSTM 滚动轴承寿命预测

张永超,刘嵩寿\*,陈昱锡,杨海昆,陈庆光

(山东科技大学机械电子工程学院,青岛 266590)

**摘要** 针对滚动轴承寿命预测精度低,构建健康指标困难的问题。提出了一种基于自适应特征融合(adaptively spatial feature fusion, ASFF)和自联想核回归模型(auto associative kernel regression, AAKR)与卷积神经网络(convolutional neural networks, CNN)和双向长短期记忆网络(bi-directional long-short term memory, BILSTM)的轴承剩余寿命预测模型。首先,在时域、频域和时频域提取多维特征,利用单调性和趋势性筛选敏感特征;其次利用 ASFF-AAKR 对敏感特征进行特征融合构建健康指标;最后,将健康指标输入到 CNN 和 BILSTM 中,实现对滚动轴承的寿命预测。结果表明:所构建的寿命预测模型优于其他模型,该方法具有更低的误差、寿命预测精度更高。

**关键词** 滚动轴承;自适应特征融合;自联想核回归;卷积神经网络;双向长短期记忆网络;剩余寿命预测  
**中图分类号** TH133.33 TP183; **文献标志码** A

## Life Prediction Based on ASFF-AAKR and CNN-BILSTM Rolling Bearings

ZHANG Yong-chao, LIU Song-shou\*, CHEN Yu-xi, YANG Hai-kun, CHEN Qing-guang

(College of Mechanical and Electronic Engineering, Shandong University of Science and Technology, Qingdao 266590, China)

**[Abstract]** To address the issues of low accuracy in rolling bearing life prediction and the difficulty of constructing health indicators, a bearing remaining life prediction model based on ASFF (adaptively spatial feature fusion) and AAKR (auto associative kernel regression) combined with CNN (convolutional neural networks) and BILSTM (bi-directional long-short term memory networks) was proposed. Firstly, the multidimensional features were extracted in the time domain, frequency domain, and time-frequency domain, and the sensitive features were screened using monotonicity and trend. Secondly, the sensitive features were feature fused using ASFF-AAKR to construct the health indicators. Finally, the health indicators were inputted into CNN and BILSTM to realize the life prediction of rolling bearings. The results show that the constructed life prediction model is better than other models, and the method has lower error and higher life prediction accuracy.

**[Keywords]** rolling bearing; adaptive feature fusion; auto associative kernel regression; convolutional neural network; bidirectional long short-term memory network; remaining life prediction

随着现代工业的高速发展,旋转机械趋于高度化、集成化、智能化的方向发展,而滚动轴承作为旋转机械的关键部位<sup>[1]</sup>,其寿命直接影响旋转机械是否正常运行。因此,对滚动轴承剩余寿命预测(remaining useful life, RUL)研究对于设备维护、机械系统正常运行具有重要意义<sup>[2-3]</sup>。

目前,对滚动轴承寿命预测大致可以分为两类:基于物理模型预测的方法、基于数据驱动预测的方法<sup>[4]</sup>;基于物理模型预测是通过建立数学退化

现象和物理模型来对关键部位的 RUL<sup>[5]</sup>, Qian 等<sup>[5]</sup>建立用来描述裂纹扩展的 Paris 公式; Deng 等<sup>[6]</sup>构建了滚动轴承的五自由度(five-degree-of-freedom, 5-DOF)动力学模型,综合考虑退化过程中的裂纹和剥落行为,实现对轴承 RUL 预测,随着旋转机械结构越来越复杂难以构建物理模型,因此基于物理模型 RUL 预测难度较高;而基于数据驱动预测的方法逐渐成为主流研究方法<sup>[7]</sup>。剩余寿命预测一般包括数据采集、构建退化指标和寿命预测 3 个步骤。

收稿日期:2024-04-07; 修订日期:2024-11-06

基金项目:山东省自然科学基金(ZR2021ME242)

第一作者:张永超(1977—),男,汉族,山东青岛人,硕士,副教授。研究方向:机电智能控制、流体机械。E-mail:jdxzyc@sdust.edu.cn。

\*通信作者:刘嵩寿(1998—),男,汉族,山东潍坊人,硕士研究生。研究方向:机电装备状态评估与寿命预测。E-mail:1057547479@qq.com。

Wang 等<sup>[8]</sup>对原始振动信号进行自适应分频,然后根据峰度指数选择最优分量,将最优分量输入 CNN 网络中实现 RUL 预测。Zhang 等<sup>[9]</sup>提出了一种卷积循环注意力网络(convolutional recurrent attention networks, CRAN),并通过试验验证了该网络的有效性。Ding 等<sup>[10]</sup>在时域、频域、小波域和熵域等提取多个特征,引入分形维数来衡量滚动轴承的退化,最后用 CNN 来拟合退化指标与多维特征之间的隐藏关系。Song 等<sup>[11]</sup>通过高斯混合模型(gaussian mixture model, GMM)和支持向量机(support vector machines, SVM)模型对轴承整个寿命周期划分为正常阶段、早期退化阶段和退化阶段 3 个阶段,引入长短期记忆网络(long short-term memory, LSTM)对轴承退化阶段实现 RUL 预测。聂磊等<sup>[12]</sup>首先提取多维特征,用主成分分析法(principal component analysis, PCA)构建健康指标(health indicators, HI),然后输入到 CNN 提取空间信息特征实现对轴承的寿命预测。慎明俊等<sup>[13]</sup>首先利用深度置信神经网络(deep belief neural, DBN)提取特征,接着利用长短期记忆网络(long-short term memory, LSTM)能记忆时间序列前后信息实现对轴承的寿命预测。上述方法只采用单一模型,往往忽略了时间序列空间特征或者时间前后关联信息。

因此,现结合 CNN 和 BILSTM 建立轴承寿命预测模型,一方面发挥 CNN 在空间提取特征的优势;另一方面利用 BILSTM 处理长时间序列优势,使模型同时具有提取空间特征能力和记忆前后信息的能力,同时用 ASFF-AAKR 模型构建的健康指标能有效反映轴承的退化程度,从而实现更精确的轴承寿命预测。

## 1 基于 ASFF-AAKR 构建退化指标和构建退化模型

### 1.1 水平振动信号特征提取

时域特征能方便看出随时间变换趋势的信息;频域特征是先将时域信号经过快速傅里叶变换(fast fourier transform, FFT)变为频域信号,从频谱信息中可以得到不同频率下频谱的信息,进而可以判断轴承随频率变换的健康状态;时频域分析可以同时从时域和频域来描述非平稳信号随时间的变化,本文研究采用 haar 小波进行 3 次小波包分解,选取最后一层 8 个节点能量特征作为时频域特征。而本文研究从时域、频域、时频域共提取 22 种特征<sup>[14]</sup>,如表 1 所示。

### 1.2 敏感特征构造

原始特征因包含大量冗余信息,不能很好地反映轴承退化信息,固对其做敏感特征的筛选,对每个

表 1 特征名称及简称

Table 1 Feature names and abbreviations

特征类型	特征名称
时域特征	方差 Var
	均值 Mean
	标准差 Std
	峰峰值 P2P
	均方根 RMS
	绝对均值 AbsMean
	偏度 Skew
	峭度 Kur
	裕度因子 MF
	脉冲因子 IF
	峰值因子 CF
频域特征	波形因子 WF
	频率均值 FMean
时频域特征	频率均方根 FRMS
	小波节点能量(NE1-NE8)

特征做趋势性和单调性的定量分析。通过趋势性 Corr 可以了解到原始特征与被测时间的关联程度,趋势性越大,原始特征与真实值越相关。单调性 Mon 可以衡量信号随时间的波动情况,单调性越大,原始特征更好地反映轴承的退化情况。两者定义为

$$\text{Corr}_i(f_i, T_i) = \frac{\text{cov}(f_i, T_i)}{\sigma_{f_i} \sigma_{T_i}} \quad (1)$$

式(1)中:  $\text{cov}(f_i, T_i)$  为第  $i$  个特征向量  $f$  与时间向量  $T$  之间的协方差;  $\sigma_{f_i}$  和  $\sigma_{T_i}$  分别为特征向量  $f$  和  $T$  的标准差。

$$\text{Mon}_i = \left| \frac{\frac{d}{df_i} > 0 - \frac{d}{df_i} < 0}{N - 1} \right| \quad (2)$$

式(2)中:  $d/df_i > 0$  和  $d/df_i < 0$  分别表示导数为正、负的个数;  $N$  为特征向量  $f$  的长度。

综合指标 Cor 是将上述两个评价指标取平均,第  $i$  个特征向量的综合指标计算式为

$$\text{Cor}_i = \frac{\text{Corr}_i + \text{Mon}_i}{2} \quad (3)$$

式(3)中:  $\text{Corr}_i$ 、 $\text{Mon}_i$  分别为第  $i$  个特征的趋势性和单调性数值。

### 1.3 ASFF-AAKR 算法

得到敏感特征后,生成的特征矩阵是多维的,不能够直接反映轴承在某一时刻的健康状态。针对上述问题,本文研究中采用 ASFF 和 AAKR 的方法将多维数据融合为一维数据,以此作为滚动轴承的健康指标。ASFF 原理为

$$d_i(x_i^t) = \frac{1}{k-1} \sum_{i \neq j, i=1}^k (x_i^t - x_j^t)^2 \quad (4)$$

$$\omega_i^t = \exp[-1 \times d_i(x_i^t)] \quad (5)$$

$$F(t) = \frac{\sum_{i=1}^k \omega_i^t x_i^t}{\sum_{i=1}^k \omega_i^t} \quad (6)$$

式中:  $d_i(x_i^t)$  为  $t$  时刻第  $i$  特征与其他不同特征平均距离;  $x_i^t, x_j^t$  为第  $i, j$  个特征向量在  $t$  时刻的值;  $\omega_i^t$  为  $t$  时刻第  $i$  特征的权重;  $F(t)$  为  $t$  时刻的 HI 值。

该算法只是在空间纵轴上对不同特征向量的压缩,而忽略了水平时间轴,本文研究中在此基础上加入 AAKF 算法<sup>[15-16]</sup>。首先用 ASFF 方法得到一维向量  $D_N^{obs}$ , 即

$$F(t) = D_N^{obs} = [F_1^{obs}, F_2^{obs}, \dots, F_N^{obs}] \quad (7)$$

在  $D_N^{obs}$  中取  $h$  个样本作健康向量  $H_h$  为

$$H_h = [F_1, F_2, \dots, F_h] \quad (8)$$

在向量  $D_N^{obs}$  中,对于任意时刻的特征值  $F_t^{obs}$  与健康向量中第  $k$  个健康值  $H(k)$  之间的距离为

$$d_k[F_t^{obs}, H(k)] = |F_t^{obs} - H(k)| \quad (9)$$

$F_t^{obs}$  与健康空间  $H$  第  $k$  个健康值的权重  $\omega_k$  为

$$\omega_k = K_h(d_k) = \frac{1}{\sqrt{2\pi}h^2} e^{-d_k^2/2h^2} \quad (10)$$

健康向量  $H(k)$  加权平均为

$$\hat{F}_t^{obs} = \frac{\sum_{k=1}^h [\omega_k H(k)]}{\sum_{k=1}^h \omega_k} \quad (11)$$

$F_t^{obs}$  与  $\hat{F}_t^{obs}$  绝对距离 HI 为

$$HI(t) = |F_t^{obs} - \hat{F}_t^{obs}| \quad (12)$$

### 1.4 CNN-BILSTM 退化模型

CNN 是一种由多层结构构成的前馈神经网络,该网络主要由卷积层、池化层和全连接层构成,其中卷积层和池化层主要用来特征提取,全连接层用来回归或者分类任务。LSTM 是循环神经网络(recurrent neural network, RNN)的一种变体,其克服了 RNN 中梯度消失和梯度爆炸的问题,其主要包括遗忘门、输入门、输出门。BILSTM 是 LSTM 的改进,由前向和后向 LSTM 共同组成,可以综合提取时间序列前后的信息特征。本文研究提出了一种 CNN 和 BILSTM 结合模型,其结构如图 1 所示。

## 2 具体操作步骤

本文研究的主要方法,如图 2 所示。从原始水平振动信号中提取时域、频域、时频域多个特征;对每个特征进行单调性和趋势性的定量分析来计算综合指标,大于特定阈值的被认为敏感特征;筛选的敏感特征通过 ASFF-AAKR 模型进行特征融合构建健康指标;将构建的健康指标输入 CNN-BILSTM 模型中,预测不同时刻轴承的寿命,并对不同模型预测结果进行误差分析。




图 1 模型结构图

Fig. 1 Model structure diagram

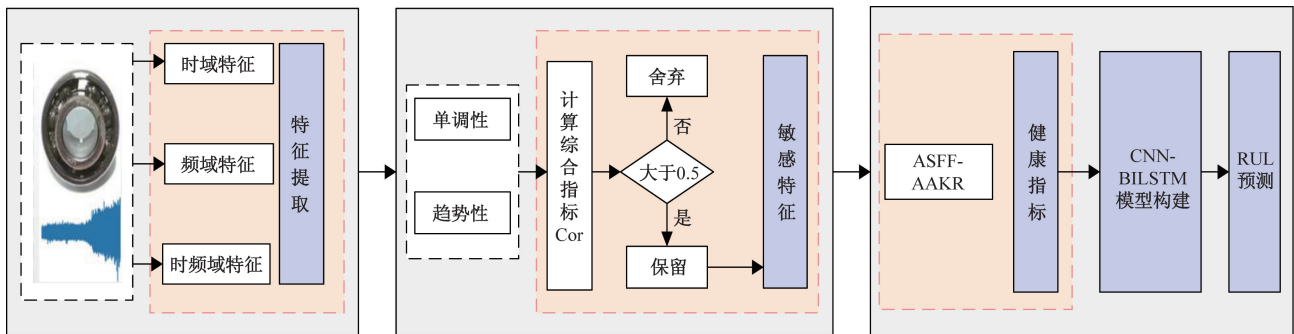


图 2 基于 ASFF-AAKR 构建退化指标和寿命预测方法流程

Fig. 2 The process of constructing degradation indicators and life prediction methods based on ASFF-AAKR

### 3 试验验证

#### 3.1 实验数据及介绍

为验证本文方法的可靠性,试验数据采用 PHM 2012。试验数据在 PRONOSTIA (图 3) 试验台上采集,该试验台上有水平和垂直两个方向加速度计,每次采样时间为 0.1 s,每 10 s 采集一次数据,数据采样频率为 25.6 kHz,每个样本有 2 560 个数据点。数据采集和试验台详细描述参见文献[17]。该数据集共包含 3 种运行状态下 17 个滚动轴承加速度振动信号,如表 2 所示。

表 2 数据集情况  
Table 2 Data sets

工况	转速/ ( $r \cdot \min^{-1}$ )	负载/ N	训练数据	测试数据
工况 1	1 800	4 000	Bearing1-1、 1-2	Bearing1-3、1-4、1-5、 1-6、1-7
工况 2	1 650	4 200	Bearing2-1、 2-2	Bearing2-3、2-4、2-5、 2-6、2-7
工况 3	1 500	5 000	Bearing3-1、 3-2	Beaing3-3

#### 3.2 方法验证

##### 3.2.1 筛选敏感特征

以 Bearing1-1 和 Bearing1-3 为例,对水平振动信号提取的 22 个特征进行窗口为 50 的平滑平均处理(moving average, MA),然后进行归一化处理。通过式(1)和式(2)计算 2 个轴承的趋势性和单调性,如图 4 所示。

利用式(3)计算所有工况下 17 个轴承的平均综合指标,并对综合指标进行归一化处理,通过设

定阈值 0.5 来筛选特征,大于 0.5 被认为敏感特征,如图 5 所示。

##### 3.2.2 构建健康指标

通过 3.2.1 节对特征筛选得到的敏感特征,首先利用式(4)~式(6)将多维数据进行自适应特征融合为一维数据  $F(t)$ ,而自联想核回归模型需要健康向量  $H_h$ ,将一维数据  $F(t)$  的前 1/10 长度每隔两个特征值取一个作为健康向量  $H_h$ ;再根据式(9)计算一维向量与每个健康值的距离,然后再利用式(10)求出每一个健康值的权重,式中  $h = 1$ ,最后利用式(11)和式(12)得到每个时刻的 HI。

基于 ASFF-AAKR 模型融合敏感特征,得到 Bearing1-1 的 HI,如图 6 所示。从图 6 可以看出前中期退化缓慢,后期退化加剧,能有效反映轴承的退化程度。

#### 3.3 模型训练与预测

##### 3.3.1 数据标签构建

对每个样本  $(X_i, Y_i)$ ,  $X_i$  是作为模型的输入,  $Y_i$  是轴承寿命标签,当  $t = 0$  时,  $Y_i$  为 1,表示轴承刚开始退化;  $Y_i = 0$  时,表示轴承完全失效。公式为

$$Y_t = \frac{N - N_t}{N} \quad (13)$$

式(13)中:  $N$  为样本点;  $N_t$  为当前监测点。

##### 3.3.2 网络参数

模型的输入将对 RUL 产生直接的影响,因此给模型输入有效的特征至关重要。本文研究将构建的 HI 采用时间窗口为 6 的处理,网络模型采用均方误差(mean square error, MSE)作为损失函数,采用 Adam 优化器,学习率为 0.001,批次为 64,迭代次数 250。本文模型参数如表 3 所示。




图 3 PRONOSTIA 平台  
Fig. 3 PRONOSTIA platform

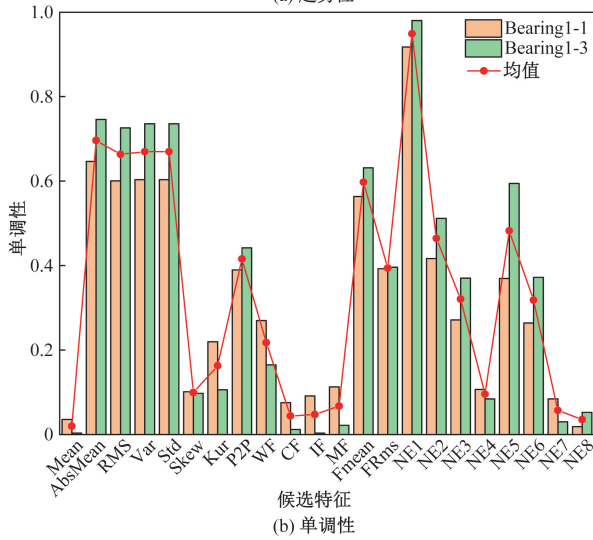
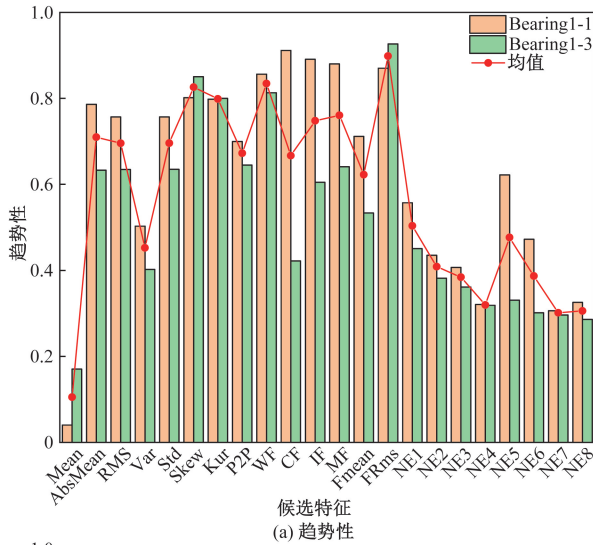


图4 Bearing1-1、1-3 趋势性和单调性指标  
Fig. 4 Bearing1-1 and 1-3 trend and monotonicity indicators




图5 综合指标  
Fig. 5 Composite indicators




图6 Bearing1-1 退化曲线  
Fig. 6 Bearing1-1 degradation curve

表3 模型结构参数

Table 3 Model structure parameters

编号	网络层	关键参数
1	卷积层	核大小: $7 \times 1$ , 数目: 32, 步长: 1
2	池化层	核大小: $2 \times 1$ , 步长: 2
3	BILSTM 层	LSTM 单元数: 128, dropout: 0.1
4	BILSTM 层	LSTM 单元数: 128, dropout: 0.1
5	Liner 层	激活函数: ReLU
6	Liner 层	激活函数: ReLU

3.3.3 模型训练

在工况 1 下,以 Bearing1-1 全寿命数据作为训练数据集, Bearing1-3 作为测试集;对于工况 2 下,以 Bearing2-1 全寿命数据作为训练数据集, Bearing2-2 作为测试集;对于工况 3 下,以 Bearing3-1 全寿命数据作为训练数据集, Bearing3-3 作为测试集。Bearing1-3 预测结果如图 7 所示,从图 7 可以看出,前期预测较差,中后期预测的趋势和真实趋势非常接近。

为了验证 CNN-BILSTM 模型的有效性,该模型预测结果与 CNN、LSTM 和 CNN-BILSTM-ATT 模型预测结果进行了对比,其结果如图 8 ~ 图 10 所示,使用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和决定系数( $R$ -square,  $R^2$ )对模型进行评价,如式(14) ~ 式(16)所示。MAE、RMAE 越小模型越好,  $R^2$  越大模型越好。

$$MAE = \frac{\sum_{i=1}^n |p_i - y_i|}{n} \tag{14}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (p_i - y_i)^2}{n}} \tag{15}$$

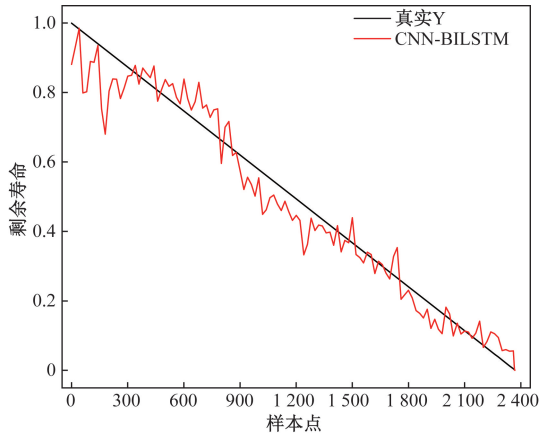


图7 Bearing1-3 寿命预测图

Fig. 7 Bearing1-3 life prediction chart

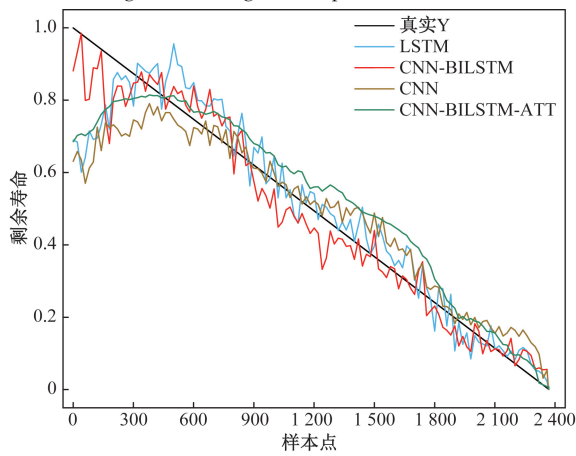


图8 Bearing1-3 各模型预测对比

Fig. 8 Comparison of predictions of each model in Bearing1-3

$$R^2 = 1 - \frac{\sum_{i=1}^n (p_i - y_i)^2}{\sum_{i=1}^n (\bar{p}_i - y_i)^2} \quad (16)$$

式中:  $p_i$  为真实值;  $y_i$  为预测值;  $n$  为样本点;  $\bar{p}_i$  为真实值的平均值。

### 3.4 分析与评价

从表4可以看出,在3种不同工况下的轴承RUL,采用CNN-BILSTM模型预测的MAE比LSTM模型平均降低了27.7%,比CNN模型和CNN-BILSTM-ATT模型分别平均降低了40.8%、17.1%;RMSE对比LSTM、CNN、CNN-BILSTM-ATT模型分

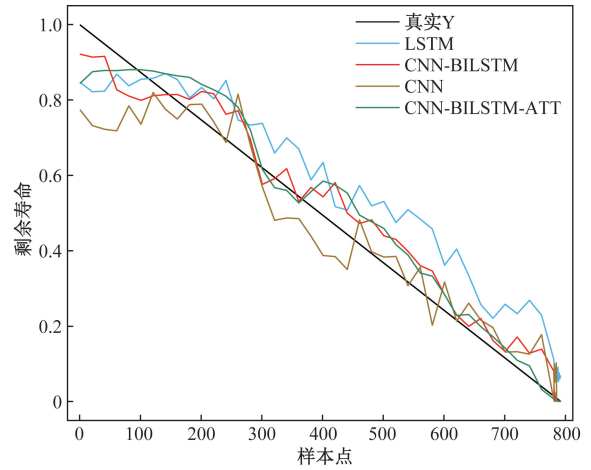


图9 Bearing2-2 各模型预测对比

Fig. 9 Comparison of predictions of each model in Bearing2-2

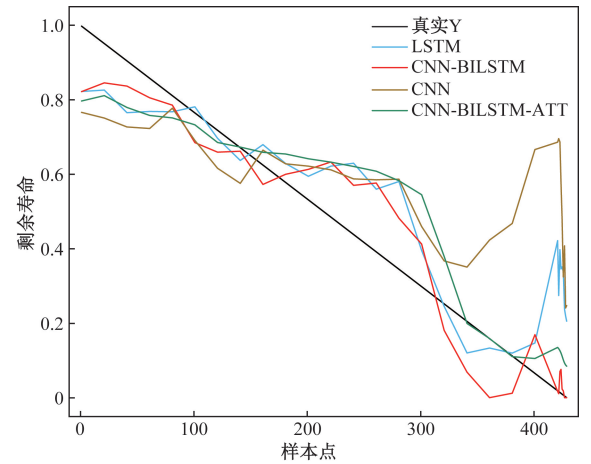


图10 Bearing3-3 各模型预测对比

Fig. 10 Comparison of predictions of each model in Bearing3-3

别平均降低了32.9%、45.5%、19.4%;  $R^2$  对比LSTM、CNN、CNN-BILSTM-ATT模型分别平均提升了9.8%、13.8%、4.97%。由此可见,本文模型预测精度更高。

## 4 结论

针对滚动轴承寿命预测精度低,构建健康指标的困难问题,提出了一种ASFF-AAKR和CNN-BILSTM模型对滚动轴承寿命预测方法,经过试验验证得出以下结论。

表4 各模型误差对比

Table 4 Comparison of errors of each model

模型	Bearing1-3			Bearing2-2			Bearing3-3		
	MAE	RMSE	$R^2$	MAE	RMSE	$R^2$	MAE	RMSE	$R^2$
LSTM	0.061 8	0.093 8	0.894 4	0.110 8	0.124 9	0.812 9	0.095 6	0.120 4	0.826 0
CNN	0.075 1	0.110 7	0.852 7	0.077 3	0.094 7	0.892 3	0.191 9	0.247 3	0.266 1
CNN-BILSTM-ATT	0.075 7	0.095 6	0.890 3	0.055 6	0.066 4	0.947 1	0.097 9	0.124 5	0.814 1
CNN-BILSTM	0.047 4	0.060 4	0.956 1	0.054 0	0.063 3	0.951 9	0.087 4	0.103 6	0.871 3

(1)首先在时域、频域、时频域提取多维特征,然后通过趋势性和单调性计算综合指标来筛选敏感特征,筛选的敏感特征有效剔除了冗余信息。

(2)将得到的敏感特征通过 ASFF-AAKR 模型进行特征融合得到健康指标,健康指标能有效反映轴承退化信息。

(3)构建的退化模型 CNN-BILSTM 相比 LSTM、CNN、CNN-BILSTM-ATT 误差更低,该模型更能精确地预测滚动轴承的寿命。

### 参 考 文 献

- [1] Zhang X, Yang J, Yang X. Residual life prediction of rolling bearings based on a CEEMDAN algorithm fused with CNN-attention-based bidirectional LSTM modeling[J]. *Processes*, 2023, 12(1): 1-8.
- [2] Deutsch J, He D. Using deep learning-based approach to predict remaining useful life of rotating components[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2017, 48(1): 11-20.
- [3] 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.
- [4] 张金豹, 邹天刚, 王敏, 等. 滚动轴承剩余使用寿命预测综述[J]. *机械科学与技术*, 2023, 42(1): 1-23.  
Zhang Jinbao, Zou Tiangang, Wang Min, et al. Review on remaining useful life prediction of rolling bearing[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2023, 42(1): 1-23.
- [5] Qian Y, Yan R, Gao R X. A multi-time scale approach to remaining useful life prediction in rolling bearing[J]. *Mechanical Systems and Signal Processing*, 2017, 83(3): 549-567.
- [6] Deng Y, Du S, Wang D, et al. A calibration-based hybrid transfer learning framework for RUL prediction of rolling bearing across different machines[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-15.
- [7] 司小胜, 胡昌华. 数据驱动的设备剩余寿命预测理论及应用[M]. 北京: 国防工业出版社, 2016.  
Si Xiaosheng, Hu Changhua. Data-driven remaining useful life prediction theory and applications for equipment[M]. Beijing: National Defense Industry Press, 2016.
- [8] Wang W, Zhao J, Ding G. RUL prediction of rolling bearings based on improved empirical wavelet transform and convolutional neural network[J]. *Advances in Mechanical Engineering*, 2022, 14(6): 16878132221106609.
- [9] Zhang Q, Ye Z, Shao S, et al. Remaining useful life prediction of rolling bearings based on convolutional recurrent attention network[J]. *Assembly Automation*, 2022, 42(3): 372-387.
- [10] Ding G, Wang W, Zhao J. Prediction of remaining useful life of rolling bearing based on fractal dimension and convolutional neural network[J]. *Measurement and Control*, 2022, 55(1/2): 79-93.
- [11] Song X, Sun J, Li C. An entire life-cycle rolling bearing remaining useful life prediction method using new degradation feature evaluation indicators[J]. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 2024; 09544089241228943.
- [12] 聂磊, 张吕凡, 徐诗奕, 等. 基于相似度特征融合和 CNN 的滚动轴承剩余寿命预测[J]. *噪声与振动控制*, 2023, 43(5): 115-121.  
Nie Lei, Zhang Lüfan, Xu Shiyi, et al. Remaining life prediction of rolling bearings based on similarity feature fusion and convolutional neural network[J]. *Noise and Vibration Control*, 2023, 43(5): 115-121.
- [13] 慎明俊, 高宏玉, 张守京, 等. 基于 DBN-LSTM 的滚动轴承剩余寿命预测模型[J]. *科学技术与工程*, 2021, 21(31): 13328-13333.  
Shen Mingjun, Gao Hongyu, Zhang Shoujing, et al. remaining useful life prediction model for rolling bearings based on DBN-LSTM[J]. *Science Technology and Engineering*, 2021, 21(31): 13328-13333.
- [14] 刘路路. 基于特征融合和 LSTM 的滚动轴承剩余寿命预测[D]. 成都: 电子科技大学, 2022.  
Liu Lulu. Remaining useful life prediction of rolling bearing based on feature fusion and LSTM[D]. Chengdu: University of Electronic Science and Technology of China, 2022.
- [15] Chen C, Xu T, Wang G, et al. Railway turnout system RUL prediction based on feature fusion and genetic programming[J]. *Measurement*, 2020, 151: 107162.
- [16] Baraldi P, Bonfanti G, Zio E. Differential evolution-based multi-objective optimization for the definition of a health indicator for fault diagnostics and prognostics[J]. *Mechanical Systems and Signal Processing*, 2018, 102: 382-400.
- [17] Nectoux P, Gouriveau R, Medjaher K, et al. An experimental platform for bearings accelerated degradation tests[C]//Proceedings of the IEEE International Conference on Prognostics and Health Management IEEE. New York; IEEE, 2012: 1-8.