DOI: 10. 13382/j. jemi. B2307000

一种基于融合特征聚类和随机配置网络的 轴承剩余寿命预测方法*

韩莹陈熙

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘 要:针对轴承剩余寿命(remaining useful life, RUL)预测中故障始发时刻(first predicting time, FPT)基于人为主观选择以及 预测滞后带来的维护风险的问题,提出了一种基于融合特征和随机配置网络(stochastic configuration networks, SCNs)的轴承剩 余寿命预测方法。首先,采用互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)对原始轴 承水平振动信号进行分解,再提取其时域、频域信号,构建融合特征。最后,使用小波聚类划分健康状态,找到合适的 FPT,并结 合能反应轴承退化的特征构建健康数据集,通过 SCNs 网络离线建模进行预测,并根据拟合曲线的斜率以及 RMSE 指标对预测 结果进行校正。通过实验分析,所提方法的综合得分高达 0.83,误差百分比的平均绝对误差(mean absolute deviation, MAD)和 标准偏差(standard deviation, SD)分别为 5.26 和 3.38;与其他预测方法相比,本文所提方法有较高的预测精度。
 关键词:轴承;剩余寿命预测;特征聚类;故障始发时刻;随机配置网络;离线预测
 中图分类号: TH136;TP277

Bearing residual life prediction method based on fusion feature clustering and stochastic configuration networks

Han Ying Chen Xi

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Aiming at the problems for which the first predicting time (FPT) of bearing remaining useful life (RUL) is based on subjective selection and maintenance risks caused by predictive lag. A stochastic configuration networks (SCNs)-based bearing residual life prediction method is proposed. Firstly, the complementary ensemble empirical mode decomposition (CEEMD) is used to decompose the original bearing horizontal vibration signal, then extract its time-domain and frequency-domain signals to construct fusion features. Secondly, the health state is divided by wavelet clustering to find the appropriate FPT, and the health data set is constructed by combining the characteristics of the energy response bearing degradation. The prediction is made by SCNs network offline modeling, and the prediction results are corrected according to the slope of the fitted curve and the RMSE index. Through experimental analysis, the comprehensive score of the proposed method is as high as 0. 83, and the mean absolute deviation (MAD) and standard deviation (SD) of the error percentage are 5. 26 and 3. 38. Compared with other prediction methods, the proposed method has higher prediction accuracy.

Keywords: bearing; residual life prediction; feature clustering; first predicting time; stochastic configuration networks; offline prediction

0 引 言

轴承是机械设备中不可或缺的重要部分,是决定设备寿命的关键部件^[1]。开展轴承剩余寿命预测的研究有

助于及时维修,可以延长设备寿命,对于安全生产有重大意义。

轴承寿命预测方法大致分为基于模型的方法和基于 数据驱动的方法。模型驱动技术工作量大,效率低,发展 缓慢;而数据驱动技术因为其无需知道其具体失效机理、

收稿日期:2023-10-25 Received Date: 2023-10-25

^{*}基金项目:国家自然科学基金(62203197)项目资助

预测结果准确等优点被越来越多地运用在轴承寿命预测 中。对于基于数据驱动进行轴承寿命预测的方法,首先 要得到一组或者多组能反应轴承退化状态的数据,但是, 因为轴承工作环境的复杂性和多变性,轴承的原始数据 往往不具备良好的趋势性。为了解决这个问题,现阶段 大多研究都选择过滤掉原始数据中的噪声部分,得到相 对稳定并且能反应轴承退化的特征,例如,一些学者对信 号使用经验模态分解(empirical mode decomposition, EMD)分解成若干内涵模态分量(intrinsic mode functions, IMF),来过滤大部分的噪声信号^[2],再提取能反应性能 退化的特征,但 EMD 分解存在着模态混叠问题。为了解 决这个问题,有专家学者在待分解的信号中加入白噪声, 提出了集成经验模态分解(ensemble empirical mode decomposition, EEMD),并把其应用在轴承寿命预测预处 理中^[3]。崔岩等^[4]提出用变分模态分解(variational mode decomposition, VMD) 处理振动信号以获得各种频率信 号,可以有效避免模态混叠问题,但是 VMD 分解出的 IMF 都具有独立的中心频率,不具备可以反应完整信息 的信号,造成许多细节方面的丢失。CEEMD 通过添加成 对的白噪声^[5],解决 EEMD 中单个白噪声产生误差的问 题,在解决模态混叠问题的同时也能得到与原始信号相 似且具有对称性的 IMF, 所以本文选择 CEEMD 进行信号 的预处理。

轴承退化过程大致分为两阶段:健康阶段和非健康 阶段^[6]。健康阶段无需进行 RUL 预测,一旦故障发生, 退化指标开始随着故障的加剧而以指数形式增加,即在 轴承退化开始后进行 RUL 预测才有意义。触发预测的 时间点被称为故障始发时刻。FPT 的选择对于 RUL 预 测极为重要,如果选择不适当,则会包含过多的干扰噪 声,影响 RUL 的预测精度。Gao 等^[7]在 RUL 预测采用滑 动窗口线性回归方法在均方根范围内建立滑动窗口,设 置阈值并通过连续触发阈值机制来确定 FPT。Zhu 等^[8] 等采用采用隐马尔可夫模型自动检测状态变化,以用来 确定 FPT。陈东楠等^[9]通过引入 Mann-Kendall 检验法和 归一化奇异值相关系数法进行状态划分。杨小东等[10] 利用根据初始时刻的轴承故障频率能量来划分退化阶 段。Chen 等^[11]等利用裕度因子对设备磨损程度的敏感 性,精确估计航空发动机转子和定子之间的摩擦冲击故 障并确定摩擦冲击位置。Benincà 等^[12]利用人类微生物 组的动态性质,由小波聚类揭示了在基于相关性的方法 中仍然模糊的群落结构,展示了小波聚类的潜力。综上 所述,本文洗择常用来检测机械设备磨损状态的裕度因 子等融合特征,并采用不考虑输入顺序的小波聚类进行 状态划分,从而更精准的确定 FPT。

轴承寿命预测的核心在于机器学习,分为在线学习 和离线学习,在线学习使模型随着数据的更新而不断更

新,而离线学习基于大量数据,不会因为个别的数据错误 使模型产生极端情况,目前轴承寿命预测大多采用离线 学习方式。Wang 等^[13]构建了多尺度卷积注意力神经网 络进行轴承剩余寿命预测,通过学习不同时间尺度的特 征,提高预测精度。车昱娇等[14]采用长短期记忆网络 (long short-term memory,LSTM)作为预测模型,能够更好 捕捉序列数据中的长期依赖关系,但其也存在一定的梯 度消失问题以及泛化性差的问题。为了解决单一源域信 息有限导致 RUL 预测精度低的问题,黄庆卿等^[15]提出了 一种多源域子域自适应的寿命预测方法。Zhang 等^[16]将 极限学习机和误差反馈神经元相结合,消除了模型的泛 化能力不足的问题,提高了参数搜索能力。并且,以上模 型都存在计算复杂度高,训练时间较长的问题。SCNs 网 络因其增量式建模方法,在减少人为干预的同时,能够有 效避免局部最优、梯度爆炸等问题,并且可以减少训练时 间,具有较强的泛化性。近些年来,SCNs网络发展迅速, 并且应用于各种场合[17]。在现阶段轴承寿命回归预测 中,大多数研究者通过建立一系列不同尺度的模型并根 据测试结果来选择最好的模型,这增加了训练时间和成 本,而 SCNs 可以在网络训练前确定理想的隐层节点数. 通过一种监督机制确保其参数的无限近似:与深度神经 网络相比.SCNs 具有更快的学习速度^[18]。所以本文选 择 SCNs 进行轴承寿命预测建模。

提前预测对于轴承的剩余寿命具有现实意义,如果 预测 RUL 大于真实 RUL,就会出现不能及时提前维修的 重大事故,而目前轴承寿命预测研究很少考虑这个问题, 本文在多次实验中发现,预测值和真实值拟合外推曲线 的起点相似,提前预测的实现就得到保证,即保证预测值 拟合外推曲线的斜率大于真实值,根据这个原理,采用拟 合外推曲线的斜率以及 RMSE 对预测结果进行校正来解 决滞后预测的问题。本文主要贡献总结如下:

1) 对裕度因子、峭度、峰值因子和均方根频率这些反 应机械磨损的特征进行分析,构建融合特征,并引入小波 聚类算法对轴承健康状态进行划分,划分结果不依赖数 据的时序性,提出了一种更为准确确定 FPT 的方法。

2)提出一种规避过高估计剩余寿命增加维修风险的 方法,采用拟合曲线的斜率以及 RMSE 对预测结果进行 校正,解决了预测结果的滞后问题。

1 信号预处理

轴承工作环境存在复杂性、多变性等特点,并不是所 有信息都对轴承的寿命预测有帮助,一些特征对轴承退 化的敏感度并不高,因此需要筛选出优秀的退化特征。

1.1 CEEMD 分解方法

CEEMD 是将正负两组辅助白噪声添加到待处理的

振动信号中,并用 EMD 分解该信号,并且因为加入的是 一正一负两组 IMF 分量,计算平均后引入的白噪声能被 有效去除,将白噪声对分解效果的影响降到最低:

$$\mathbf{m}_{1}^{+}(t) = x(t) + n_{1}^{+}(t) \tag{1}$$

$$m_1(t) = x(t) + n_1(t)$$
 (2)

式中: x(t) 为原始信号; $n_1^+(t)$ 为正的白噪声; $n_1^-(t)$ 为 负的白噪声; $m_1^+(t)$ 为添加正的白噪声后的信号; $m_1^-(t)$ 为添加负的白噪声后的信号。

分别对 $m_1^+(t)$ 和 $m_1^-(t)$ 进行经验模态分解后,得到 两组 IMF,然后将对应的每一阶 IMF 相加并求其均值:

$$IMF = (IMF^{+} + IMF^{-})/2$$
(3)

式中: IMF^+ 和 IMF^- 分别为 $m_1^+(t)$ 和 $m_1^-(t)$ 经过 EMD 分解后得到的 IMF。

1.2 特征提取

进行 CEEMD 分解后得到的信号相较于原始信号更 加稳定,预测效果也更好,但其趋势性不明显,不能反应 轴承的退化。而当轴承出现故障时,其时域和频域特征一 定会发生变化,所以提取分解后信号的时域和频域特征: 峭度、峰峰值、方根幅值、平均幅值、均方根值、峰值、方差、 峰值因子、波形因子、裕度因子、脉冲因子、平均频率、频率 方差、频率标准差、均方根频率。并根据时间相关性的大 小,选择这些特征中对轴承退化的敏感度的特征。

1.3 特征选择

不相关的特征存在不能反应轴承退化过程或者丢失 退化过程中的细节等问题,会影响后续预测模型的性能, 因此,有必要消除这些特性,而只保留那些有贡献的特 征。皮尔逊相关系数通常用于度量两组样本数据之间的 相似性,其数值越大,证明两组数据更接近,时间相关性 则是把一组数据换成时间数据,同样,数值越大,证明与 随时间的变化越明显。

对于数据集 $X(x_1, x_2, \dots, x_n)$ 和数据集 $Y(y_1, y_2, \dots, y_n)$ 的皮尔逊相关系数如下:

$$r = \frac{Cov(X,Y)}{S_X S_Y} = \frac{\sum_{i=1}^{n} (x_i - \bar{x}) (y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n} (x_i - \bar{x})^2 \sum_{i=1}^{n} (y_i - \bar{y})^2}} \quad (4)$$

式中: Cov(X,Y) 是两组数据集的协方差, $S_x \, {}_x S_y$ 分别是 数据集 X和 Y的标准差, $x \, {}_x y \, {}^-$ 分别是两组数据集的均值, n 为数据量。

经过与原始数据集皮尔逊相关系数以及时间相关性 的对比,可以得到反应轴承退化过程的特征集。

2 健康状态识别

经过预处理的数据集的一部分数据在后续 RUL 预

测过程中作用很小甚至会降低预测精度,这是因为在实际轴承失效的过程中,系统的状态通常会随时间而变化,如从开始运行到平稳运行到快速退化状态,而平稳运行状态不具备预测意义,所以,为了分析系统的各种可能的状态,提出对轴承的融合特征进行小波聚类,得到最可能的状态。健康状态划分的目的是得到有趋势性、有预测价值的快速退化状态,FPT的选择至关重要,传统的FPT选择方法都基于均方根等时序性强的特征,受人为主观影响过大。对此,本文采用特征融合分析方法,更为客观。

通过计算皮尔逊相关系数,选择裕度因子、峭度、峰 值因子和均方根频率作为划分健康状态的特征。裕度因 子常被用于小型机械的故障诊断,对冲击性故障比较敏 感,用来检测设备的磨损情况,是表征轴承性能退化的指 标。从图1中可以看出,裕度因子信号复杂,包含信息过 多,但存在整体趋势由低逐渐变高并由高变低部分以及 趋势较为平坦部分,可以根据每次的最高点将整个轴承 寿命分成多个阶段,具有一定的规律性。采用小波聚类 将裕度因子进行状态划分,如图2所示。



图 2 裕度因子小波聚类 Fig. 2 Wavelet clustering of margin factor

0.23 0.22

如图 2 所示,0 标识的点为离散点,而 1~5 点则被划 分成为5部分,并且其随横轴均匀分布。结合原始数据 的变化趋势,本文以每个状态的起点为分界点,将整个轴 承状态划分为5类,分别是波动状态、健康状态、中间波 动状态、快速退化状态以及完全退化状态,本文将快速退 化点开始点记为 FPT。在多次实验中发现,大多数轴承 并没有进入到完全退化状态,或者因为完全退化状态过 短被聚类自动标记为离散点。所以,本文的轴承划分大 多为除去完全退化状态后的4类,而 FPT 处于快速退化 状态之前,这并不影响 FPT 的确定。

裕度因子在小波聚类后,可以将轴承不同阶段的状 态分别聚到一起,但没有明显的分界点,所以对数据进行 平滑处理如图3所示。



将图 3 与图 2 对比可以的得到,经过平滑处理后,可 以明显划分成不同阶段,但仍然存在状态点不连续、阶段 划分不明显的问题,不能准确地确定 FPT,为了加强各个 阶段的特征,本文分析与裕度因子相似的特征如图 4~6 所示。









Fig. 6 Root mean square frequency clustering

确确定 FPT 的位置,进行综合考虑,将4个特征重新融 合,其小波聚类如图7所示。



由图7可以看到,融合特征划分效果更明显,离散点 更少,可以清晰的把轴承全寿命周期分为波动状态、健康 状态、中间波动状态以及快速退化状态。

3 预测模型

3.1 SCNs 模型

SCNs 的典型的结构模型如图 8 所示。



其中, z_d 和 f_d 分别表示输入、输出样本, b_L 表示隐藏 层神经元的个数, L_{max} 表示最大隐含层节点数,那么,第j个隐含层节点的输出为:

 $f_i = \sigma(\omega_i^{\mathrm{T}} X + [b_i]) \tag{5}$

其中,σ(・)是激活函数,ω_j为输入权重,b_j为偏差。 随机生成ω和b,并计算更新输出权值β,隐藏层节 点数加1,得到模型新的输出为:

$$\boldsymbol{Y} = \boldsymbol{Y}_{L-1} + \boldsymbol{\beta}_L \cdot \boldsymbol{f}_L \tag{6}$$

其中, $\beta = [\beta_1, \beta_2, \dots, \beta_M]_{L \times M}$ 为隐含层和输出层之间的输出权值。

3.2 规避高估 RUL 风险

本文对真实值和预测值做多项式拟合,得到真实拟合直线的斜率 K_i 以及预测拟合直线的斜率 K_p,预测过程中加入限制条件为:

K_P	$\geq K_t, K_p$	> 0	(7)
•• <i>p</i>	_t ,p		('	

$$K_p \le K_t, K_p \le 0 \tag{8}$$

同时,基于多次实验发现,当 RMSE>0.1 时,会出 现预测结果超前过多的现象。为了避免这一缺陷,并 且基于模型预测精度足够高,不会出多次校正没有结 果的情况,加入约束条件 RMSE<0.1,如果不满足则 将数据再次输入 SCNs 模型进行预测,可以避免误差 过大导致预测剩余寿命过小的问题,具体过程如图 9 所示。

3.3 基于 SCNs 模型的滚动轴承 RUL 预测

轴承 RUL 预测是根据经过合适的特征提取和选择 后得到与故障最直接关联的特征参数后,基于这个特征 变化对轴承健康程度进行预测。基于 SCNs 模型的滚动 轴承 RUL 预测过程如图 10 所示。



Fig. 9 Calibration process

4 实验结果及分析

4.1 轴承寿命数据集

为了验证本文所采用方法的有效性,采用 PHM 2012 挑战赛轴承加速寿命实验数据^[19]进行验证。该数据集 来自如图 11 所示的试验台。

实验所得到的数据集包含由加速度计在水平和垂直 方向上捕获的轴承振动信号,以及相关的温度数据。振 动信号采集实验设置如下,传感器采样频率设定是 25.6 kHz,设定实验开始后每隔 10 s 采集加速度数据,每 次采集 0.1 s 的数据,即每段数据为 2 560 个点的数据 列。实验过程中,为了保证试验台不会被轴承的严重故 障破坏,设置当传感器采集到的加速度数值连续超过 20 g停止试验,认定此时轴承剩余寿命为 0。

水平振动信号包含更多关于轴承工作状态的信息^[20],所以采用水平振动信号作为实验对象,以轴承1-1为例,其原始数据如图12所示。

4.2 数据预处理

1) 时频分析

本文对轴承 1-1 的水平振动信号进行 CEEMD 分 解,提取出包含大部分细节的轴承退化信号。为了验证 方法的合理性,对原始数据分别进行 EMD、EEMD、 CEEMD 和 VMD 分解。在保证 EEMD 和 CEEMD 添加高 斯白噪声的均方差和总体平均次数一致的情况下,其皮 尔逊相关系数如表 1 和图 13 所示。



图 10 寿命预测流程 Fig. 10 Life prediction flow chart



图 11 PRONOSTIA 试验工作台 Fig. 11 PRONOSTIA test bench

表1 不同分解方法的皮尔逊相关系数

 Table 1
 Pearson correlation coefficients for different decomposition methods

分解方法	IMF1	IMF2	IMF3	IMF4	IMF5
EMD	0.642 5	0.424 5	0.3379	0.256 5	0.174 6
EEMD	0.7387	0.5457	0.3811	0.2612	0.1607
CEEMD	0.7891	0.5660	0.3790	0.244 2	0.1890
VMD	0.364 0	0.381 0	0.3951	0.392 6	0.410 0



图 12 轴承 1-1 水平方向全寿命振动信号 Fig. 12 Horizontal full-life vibration signal of bearing 1-1

从表1和图13中可得,在相同条件下,CEEMD在保证得到平稳信号的前提下,其IMF1与原始数据的皮尔逊相关系数更大,即保留了绝大部分原始数据的信息,故选择其进行下一步信号处理。

2) 时域和频域

对 CEEMD 分解所得的 IMF1 提取其时域和频域特征,部分代表性特征如图 14 所示。

由图 14 可知,特征变化大致可以分为 3 类,特征 (a)、(b)、(c)随着时间变化有明显的增大趋势,特征 (d)也存在向上趋势,但大部分时间趋势不明显,特征









(e) 峰值因子 (e) Peak factor (f)和(e)则不具备随时间变化的趋势,不能用作寿命预测。本文对全部特征进行时间相关性分析如图 15 所示。

由图 15 可知,在方差之前的特征均有随着时间变化的趋势,故选择方差之前的特征构建健康数据集。

4.3 预测模型

使用 ESN、SVM、LSTM、TCN-LSTM、CNN-LSTM 和 SCNs 几种模型进行对比分析,网络参数设置如表 2 所 示。最终预测结果如图 16 和表 3 所示。

由图 16 可以看出, SCNs 模型的预测更接近于真实 值,并且其爬坡能力优于其他各个模型;且根据表 3 结 果, SCNs 模型的评价指标是表现最好的。

4.4 健康状态划分

对融合特征进行小波聚类,划分轴承状态,效果如图 17 所示。



图 14 轴承 1-1 部分时域特征 Fig. 14 Time domain characteristics of bearing part 1-1





Fig. 15 Temporal correlation of bearing features

表 2	、不	同模型	参数
			~

Та	ble 2 Parameters of different models
模型	参数
SVM	c = 1 000; g = 0.1
ESN	ResSize: 100-10; rhow: 0.899-0.8; learningrate = 0.01
LSTM	MiniBatchSize = 128; $MaxEpochs = 500$; $learningrate = 0.01$
TCN-LSTM	numChannel = 16; KerSize = 3; dropoutFactor = 0.05 MiniBatchSize = 128; MaxEpochs = 500; learningrate = 0.01
CNN-LSTM	MiniBatchSize = 128; MaxEpochs = 500; learningrate = 0.01
SCNs	$L_{\text{max}} = 200$; tol = 0. 001; $T_{\text{max}} = 50$



图 16 不同模型预测效果对比



表3 不同模型预测评价指标

Table 3 Prediction evaluation indicators

of different models

预测模型	RMSE	MAE	MSE
SVM	1.246 9	1.1654	1.5547
ESN	0.3057	0.237 8	0.093 4
LSTM	0.2906	0.0914	0.084 4
TCN-LSTM	0.214 6	0.208 4	0.046 1
CNN-LSTM	0.1516	0.085 7	0.012 3
SCNs	0.134 3	0.044 7	0.018 1



如图 17 所示,经过小波聚类状态划分点存在明显倾斜,本文选择快速退化状态的起点,也就是 1510 点为 FPT。为了验证 FPT 选择的准确性,选择 FPT 附近的多 个点以及采用单个特征确定的 FPT(1846)与本文方法所 选 FPT(1510)进行对比,由 SCNs 对其进行检验。

从表 4 可以看出,将 1510 作为 FPT 预测效果最好。

表 4 FPT 选择 Table 4 FPT selection

FPT 选择	RMSE	MAE	MSE
全寿命周期(10 s)	0.426 0	0.108 4	0.181 5
1300	0.378 9	0.138 5	0.143 6
1400	0.323 6	0.111 0	0.1047
1510	0.1006	0.047 5	0.010 1
1600	0.203 9	0.078 5	0.041 6
1700	0.3123	0.1269	0.097 6
1846	0.3463	0.164 3	0.119 2

如图 18 所示,整体预测效果呈现出一个凹的趋势, 并且以 1510 点为分界,1510 点之前预测效果逐渐变好, 1510 点之后预测效果逐渐变差,进一步验证了融合特征 进行状态划分的准确性。



4.5 消融实验

为验证算法中每个部分的有效性,进行消融实验,选择不确定 FPT、不进行 CEEMD 分解、不进行特征选择以及不进行数据矫正进行实验,如表 5 所示。

表 5 消融实验 Table 5 Ablation experiment

	RMSE	MAE	MSE
无 CEEMD 分解	0.658	0.190	0.433
无特征选择	0.966	0.242	0.934
不确定 FPT	0.223	0.079	0.223
不进行校正	0. 599	0.172	0.359
完整实验	0.077	0.044	0.005

表 5 消融实验综合评估了各个部分的性能,同时可 证明本文算法中的每一部分都是不可或缺的。

4.6 RUL 预测结果和讨论

由于轴承处于健康状态时预测 RUL 是没有意义的, 所以选择退化状态起点后开始进行轴承 RUL 预测。对 FPT 后的数据建立 HI 曲线,并且由于各个轴承之间存在 差异,难以规定一个固定的失效阈值,故选择对开始退化 到完全失效部分建立 0~1 无量纲的 HI 训练标签,失效 阈值为 1。如图 19 所示,以轴承 1-3 为例。



Fig. 19 Life prediction diagram of Bearing 1-3

轴承 1-3 的预测剩余寿命为 5 830 s,而其真实剩余 寿命为 5 730 s,预测寿命大于真实寿命,这就会导致在实 际应用过程中不能及时维修而出现一系列事故。本文提 出对预测结果进行校正,根据预测误差与 RUL 的关系 (即斜率)进行微调,避免预测滞后带来的风险,加入限 制条件后的寿命预测结果如图 20 所示。

如图 20 所示,在实验过程中,预测值拟合曲线在实际使用寿命参考线之上,保证了在实际应用过程中预测RUL小于真实 RUL,做到提前预测。

为了验证本文方法的泛化性,本文选择同轴承不同



Fig. 20 Forecast diagram of bearing 1-3 after correction

工况、不同轴承同种工况以及不同轴承不同工况进行对 比。由于篇幅限制,本文选择其中具有代表性的工况1 和2中各3个轴承进行实验,如图21所示。

如图 21,所有预测值拟合曲线均在实际剩余寿命参 考线上方,且预测 RUL 接近真实 RUL,如表 6 所示。

表 6 预测结果 1 比较 Table 6 Comparison of prediction results 1

实验	真实 RUL/s	预测 RUL/s	Er	校正前 Er
轴承 1-3	5 730	5 610	2.09	-1.74
轴承 1-4	339	320	5.60	-26.54
轴承 1-7	7 570	7 470	1.32	-0.52
轴承 2-3	7 530	6 730	10.62	19. 52
轴承 2-4	1 390	1 300	6.47	12.23
轴承 2-6	1 290	1 220	5.42	8.52
Score			0.83	0.60
MAD			5.25	11.51
SD			3.38	16.05

使用 IEEE PHM 2012 数据挑战赛中使用的评分函数,定义如下:

Score =
$$\frac{1}{6} \sum_{i=1}^{6} A_i$$
 (9)

其中:

$$A_{i} = \begin{cases} \exp(-\ln(0.5) \cdot (Er_{i}/5)), Er_{i} < 0\\ \exp(+\ln(0.5) \cdot (Er_{i}/20)), Er_{i} > 0 \end{cases}$$
(10)

 Er_i 为预测结果的误差自分比,定义如下

$$Er_i = \frac{ActRUL_i - RUL_i}{ActRUL_i} \times 100\%$$
(11)

另外,为了评价 RUL 预测结果的稳定性,还计算了 误差百分比的 MAD 和 SD。由表 6 结果,校正后得分更 高,误差也更小,并且校正后的 RUL 都小于真实 RUL,即 校正后的均为正数,解决了预测结果滞后的问题,保证了 提前预测。



Fig. 21 Generalization experiment

为了进一步验证本文方法的有效性,将其与另外 3 种方法进行对比,对比结果如表 7 所示。

	表 7	预测结	ま果2比较		
Table 7	Com	parison	prediction	results	2

		•		
实验	校正 SCNs	Xu ^[21]	Wang ^[22]	Zhang ^[23]
轴承 1-3	2.09	-2.61	5.06	2.27
轴承 1-4	5.6	17.4	23.3	5.6
轴承 1-7	1.32	1.05	-42.54	-22.46
轴承 2-3	10.62	0.25	17.4	0.99
轴承 2-4	6.47	-2.87	12.23	5.76
轴承 2-6	5.42	13.95	-2.32	-10.85
Score	0.83	0.74	0. 53	0.63
MAD	5.25	6.35	17.13	7.98
SD	3.38	8.83	23.68	9.88

由表7结果,几种对比方法中,本文所提出的方法得

分最高,SD和 MAD 值最小,且预测误差更稳定且全为正数,这表明所提出的模型 RUL 预测结果更准确也更稳定,保证了提前预测,且预测效果更好,验证了本文方法的可行性和优越性。

5 结 论

本文提出了一种基于 SCNs 网络的轴承融合特征选择 RUL 预测方法。该方法采用时间相关性小但包含更多信息的特征构建融合特征并结合小波聚类来确定FPT,能够从不依赖时间变化性的角度检测轴承的健康状态,能够准确确定 FPT;另一方面利用拟合曲线的斜率来解决预测结果滞后问题,从而大大提高了 RUL 预测的精度以及现实意义。选择能够精确地反应整个轴承运行状态的特征,并结合其他因素,更加准确地确定 FPT 以

及预测 RUL,是本文未来的一个研究方向。

参考文献

- [1] CHENG C, MA G, ZHANG Y, et al. A deep learningbased remaining useful life prediction approach for bearings [J]. IEEE/ASME Transactions on Mechatronics, 2020, 25 (3): 1243-1254.
- [2] 吕峥,庄炜,吴越,等.基于改进 EMD 方法的 FBG 传感 网络光谱基线校正研究[J]. 仪器仪表学报,2022,43(1):190-197.

LYU ZH, ZHUANG W, WU Y, et al. Research on spectral baseline correction of FBG sensor network based on improved EMD method [J]. Chinese Journal of Scientific Instrument, 2022, 43(1):190-197.

[3] 肖旰,周莉,李敬兆,等. 基于 EEMD 融合 BAS-CNN 的 高压电缆故障诊断[J]. 电子测量技术,2022,45(4): 160-167.

> XIAO Y, ZHOU L, LI J ZH, et al. Fault diagnosis of high voltage cable based on EEMD fusion BAS-CNN[J]. Electronic Measurement Technology, 2022, 45 (4): 160-167.

[4] 崔岩,方春华,文中,等.基于 VMD-WOA-ELM 的电缆
 外力破坏振动信号在线识别[J].电子测量技术,
 2023,46(2):121-129.

CUI Y, FANG CH H, WEN ZH, et al. Online identification of vibration signal of external force damage in cable based on VMD-WOA-ELM [J]. Electronic Measurement Technology, 2023, 46(2):121-129.

- [5] YEH J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method [J]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.
- [6] YAN B, MA X, HUANG G, et al. Two-stage physicsbased wiener process models for online RUL prediction in field vibration data [J]. Mechanical Systems and Signal Processing, 2020, 152: 107378.
- [7] GAO S, LV C, WU X, et al. Method for determining starting point of rolling bearing life prediction based on linear regression[J]. Electronics, 2019, 8(9): 923.
- [8] ZHU J, CHEN N, SHEN C. A new data-driven transferable remaining useful life prediction approach for bearing under different working conditions [J]. Mechanical Systems and Signal Processing, 2020, 139: 106602.
- [9] 陈东楠,胡昌华,郑建飞,等. 状态划分下基于 Bi-LSTM-Att 的轴承剩余寿命预测[J]. 空间控制技术与

应用,2023,49(4):29-39.

CHEN D N, HU CH H, ZHENG J F, et al. Prediction of remaining life of bearings based on Bi-LSTM-Att under state division [J]. Space Control Technology and Application, 2023, 49(4):29-39.

- [10] 杨小东,纪国宜. 基于融合 CNN 的滚动轴承剩余寿命 预测[J]. 国外电子测量技术,2021,40(3):62-67.
 YANG X D, JI G Y. Prediction of remaining life of rolling bearings based on fusion CNN [J]. Foreign Electronic Measurement Technology, 2021, 40(3): 62-67.
- [11] CHEN W, YU M, WU P. Rotor-stator rub-impact fault and position identification of aero-engine based on VMD-MF-Cepstrum-KNN [J]. Tribology Transactions, 2023, 66(1): 23-34.
- [12] BENINCÀ E, PINTO S, CAZELLES B, et al. Wavelet clustering analysis as a tool for characterizing community structure in the human microbiome [J]. Scientific Reports, 2023, 13(1): 1-14.
- [13] WANG Y, WANG J, ZHANG S, et al. Remaining useful life prediction model for rolling bearings based on MFPE-MACNN[J]. Entropy, 2022, 24(7):905-905.
- [14] 车昱娇,陈云霞,崔宇轩. KPCA 和改进 LSTM 在滚动 轴承剩余寿命预测中的应用研究[J]. 电子测量与仪 器学报,2021,35(02):109-114.
 CHE Y J, CHEN Y X, CUI Y X. Application of KPCA and improved LSTM in residual life prediction of rolling bearings [J]. Journal of Electronic Measurement and Instrumentation,2021,35(2):109-114.
- [15] 黄庆卿,胡欣堪,韩延,等. 多源域子域自适应的滚动 轴承剩余寿命预测方法[J]. 电子测量与仪器学报, 2022,36(10):100-107.
 HUANG Q Q, HU X K, HAN Y, et al. Multi-source domain sub-domain adaptive prediction method for remaining life of rolling bearings [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10):100-107.
- [16] ZHANG J, DAI Y, XIAO Y. A model for remaining useful life prediction of rolling bearings based on the IBA-FELM algorithm [J]. Measurement Science and Technology, 2024, 35(3):035021.
- [17] NIU H, WEI J, CHEN Y. Optimal randomness for stochastic configuration network (SCN) with heavy-tailed distributions[J]. Entropy, 2020, 23(1): 56.
- [18] GAO Y, LUAN F, PAN J, et al. FPGA-based implementation of stochastic configuration networks for

regression prediction [J]. Sensors, 2020, 20(15):4191.

- [19] NECTOUX P, GOURIVEAU R, MEDJAHER K, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests [C]. IEEE International Conference on Prognostics and Health Management. IEEE, 2012.
- [20] ZHENG Y. Predicting remaining useful life based on Hilbert-Huang entropy with degradation model [J]. Journal of Electrical and Computer Engineering, 2019, 2019(1): 3203959. 1-3203959. 11.
- [21] XU W, JIANG Q, SHEN Y, et al. RUL prediction for rolling bearings based on convolutional autoencoder and status degradation model [J]. Applied Soft Computing, 2022, 130: 109686.
- [22] WANG B, LEI Y G, LI N, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.
- [23] ZHANG G, LIANG W, SHE B, et al. Rotating machinery remaining useful life prediction scheme using deep-learningbased health indicator and a new RVM [J]. Shock and Vibration, 2021, 2021(8): 1-14.

作者简介



韩莹(通信作者),2005年于辽宁工程 技术大学获得学士学位,2008年于辽宁工 程技术大学获得硕士学位,2020年于东北 大学获得博士学位,现为辽宁工程技术大学 副教授,主要研究方向为时间序列分析与应 用、故障预测与健康管理等。

E-mail: hyfengyan@163.com

Han Ying (Corresponding author) received her B. Sc. degree from Liaoning Technical University in 2005, M. Sc. degree from Liaoning Technical University in 2008 and Ph. D. degree from Northeastern University in 2020, respectively. Now she is an associate professor in Liaoning Technical University. Her main research interests include time series analysis and application and prognostics health management.



陈熙,现为辽宁工程技术大学电气工程 专业在读硕士研究生,主要研究方向为轴承 寿命预测、智能优化算法等。

E-mail: 13152996488@163.com

Chen Xi is now a M. Sc. candidate in

Liaoning Technical University. His main research interests include bearing life prediction, intelligent optimization algorithm, etc.