DOI: 10.3901/JME.2021.21.088

一种基于空间卷积长短时记忆神经网络的轴承 剩余寿命预测方法*

王久健^{1,2} 杨绍普² 刘永强² 文桂林¹

(1. 湖南大学汽车车身先进设计制造国家重点实验室 长沙 410082;

2. 石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室 石家庄 050043)

摘要: 传统的基于数据驱动的轴承剩余预测方法仍需要一定的先验知识, 比如: 特征指标选取、健康指标构建、失效阈值选定等等。预测结果严重依赖人工经验, 为了克服这一缺点, 基于深度学习方法提出了一种用于轴承剩余寿命预测的新方法, 该方法的核心包括健康指标构建和剩余寿命计算。首先提出了一种无需先验知识的基于空间卷积长短时记忆神经网络(Convolutional long short-term memory neural network, ConvLSTM)的健康指标生成网络模型, 该网络利用卷积神经网络的局部特征提取能力和长短时记忆网络的时间依赖特性, 可直接从采集到的原始信号中挖掘反映退化程度的特征, 构建健康指标, 实现了高维原始数据向低维特征的映射转化, 并利用 Sigmoid 函数将其归至[0,1]区间内, 实现了阈值的统一; 然后, 利用粒子滤波更新双指数寿命模型, 实现剩余寿命结果的输出。利用轴承全寿命试验对所提方法进行了验证, 并与其他相关方法进行对比, 结果表明本文方法所构建的健康指标具有更好的趋势性、单调性和鲁棒性, 同时剩余寿命预测的准确率更高。

关键词: 滚动轴承; 剩余寿命预测; 健康指标; 深度学习; ConvLSTM

中图分类号: TH17

A Method of Bearing Remaining Useful Life Estimation Based on Convolutional Long Short-term Memory Neural Network

WANG Jiujian^{1,2} YANG Shaopu² LIU Yongqiang² WEN Guilin¹

(1. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha 410082;

2. State Key Laboratory of Mechanical Behavior in Traffic Engineering Structure and System Safety, Shijiazhuang Tiedao University, Shijiazhuang 050043)

Abstract: Traditional prediction methods of bearing remaining useful life estimation based on data driven method still need some prior knowledge, such as feature index selection, health index construction, failure threshold selection and so on. In order to overcome this shortcoming, a new method for bearing residual life prediction based on deep learning method is proposed. The core of this method includes health index construction and remaining useful life calculation. First proposed a without prior knowledge of health indicators generated neural network based on ConvLSTM, the network combines the local feature extraction ability of convolutional neural network and long length of time dependent characteristics of long short-term memory neural network. This network can directly mining the characteristics of degradation degree from the original signal and build health indicators to realize the original high-dimensional data to lower dimensional feature mapping. And it uses the Sigmoid function to unify the threshold to [0, 1] interval, realized the unification of the threshold value; Then, the particle filter is used to update the double exponential life model to realize the output of the remaining life results. The method is verified by bearing life test and compared with other related methods. The results show that the health index constructed by this method has better trend, monotonicity and robustness, and the accuracy of remaining useful life prediction is higher.

Key words: rolling bearing; RUL; health indicator; deep learning; ConvLSTM

* 国家自然科学基金(11790282, 12032017, 11802184, 11902205, 12002221)、河北省科技计划(20310803D)和河北省自然科学基金(A2020210028)资助项目。20201118收到初稿, 20210618收到修改稿

0 前言

滚动轴承是旋转机械中的重要组成部分,起到支撑机械旋转体高精度回转的重要作用,属于易损伤的关键部件。轴承随着生产的进行,在内外综合因素的影响下,性能和健康状态不可避免会呈现退化现象,且其剩余寿命(Remaining useful life, RUL)也会出现不同趋势的退化过程。当轴承的剩余寿命结束之前,如果没有采取相应的维护措施,设备将无法完成正常的生产任务,甚至会产生安全隐患,对生命和财产造成威胁^[1-3]。因而,对关键部位滚动轴承的运行的剩余寿命进行掌控,对指导制定设备维保策略,保证设备的安全运行至关重要。剩余寿命预测方法主要分为三类:基于失效机理方法、基于监测数据驱动的方法以及二者融合的方法^[4,5]。基于失效机理分析方法能够准确预测设备的剩余寿命。但需要根据具体对象建立相应的退化模型,一般不具有普适性,同时随着设备精密性和复杂度的提高,很难建立系统对象的失效模型或者获得失效模型的代价过高。数据驱动的方法是基于传感器采集到的数据,利用机器学习和概率统计的方法,从数据中挖掘与剩余寿命间的存在映射关系的特征指标,是当前 RUL 预测的主流方法之一^[6]。数据驱动主要分为 3 步:数据采集、健康指标建立、寿命预测。健康指标(Health indicator, HI)是从采集到的数据中提取有效特征,将其构建成可定量描述设备的退化过程的指标。所以,健康指标构建的好坏,直接影响 RUL 预测的准确性。

为了更加准确地定量描述设备性能的衰退过程,很多学者致力于健康指标构建方法的研究。文献[7]基于小波包分解出不同频带的信号,通过 Rényi 熵构建轴承健康指标。MOSTAFA 等^[8]使用 dispersion-entropy 描述设备的退化过程。WANG 等^[9]利用滑动平均方法对泥浆泵的性能退化指标进行了构建。这些研究提出了有效单一指标对设备的健康状态进行评价。YU^[10]提出利用局部投影算法,对时域和频域等指标的流行结构进行分析,进而构建出轴承退化情况的指标;又通过计算两个马尔柯夫过程模型的概率密度来实现健康指标的构建^[11]。余道明等利用自动编码器网络对时频域指标进行降维提取特征,用 SOM 网络进行信息融合,输出健康指标^[12]。HONG 等^[13]利用 WP-EMD 对振动信号提取特征,利用 SOM 网络进行融合生成健康指标。GUO 等^[14]通过计算 24 个

时域、频域和时频域指标与寿命的相关性,挑选 6 个敏感指标作为 RNN 网络的输入,利用构建的 RNN-HI 模型将输入指标融合为一个表现轴承性能退化的健康指标。

由上可以发现,轴承健康指标的构建逐渐由单一的有效指标转向由原始信号所提取的多个指标的融合方式发展。直接从原始信号提取的指标一般为时域、频域和时频域等指标,但这些基础指标仍为研究者人为挑选的特征指标,存在主观和经验的依赖。深度学习作为近些年兴起的数据挖掘的有效工具,能够基于数据训练神经网络模型参数,挖掘出数据内部的隐藏特征,并建立特征与分析目标间的映射关系。受此思想的激发,本文尝试利用深度神经网络,直接从采集到的原始信号中挖掘反映退化性能的特征,构建出描述设备状态的健康指标,省去人工计算特征、挑选特征的过程,降低构建健康指标过程中对经验知识的依赖。鉴于此,本文提出了一种基于 ConvLSTM 深度神经网络的健康指标构建模型,并结合双指数寿命模型实现了 RUL 的预测。

1 基础理论

1.1 长短时记忆网络

长短期记忆(Long short-term memory, LSTM)网络^[15-16]是循环神经网络的一个变体,可以有效地解决简单循环神经网络的梯度爆炸或消失问题。其在 RNN 网络的基础上,引入门控机制来控制信息的累积速度,包括有选择地加入新的信息,并有选择地遗忘之前累积的信息。LSTM 的具体公式如下

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (2)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (3)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (4)$$

$$h_t = o_t \odot \tanh(c_t) \quad (5)$$

式中, i, f, o 分别代表输入门、遗忘门和输出门; c 和 h 分别代表记忆单元和外部状态; $\sigma(\bullet)$ 为 Logistic 函数,其输出区间为(0,1); $\odot$ 代表 Hadamard 乘积算子; W 代表各个神经元的权重,其与输入矢量 x_t 和外部状态 h_{t-1} 直接点乘,因此该种 LSTM 网络也被称为全连接型长短时记忆(Full connected long short-term memory, FC-LSTM)网络。

图 1 为 LSTM 网络的循环单元结构,其计算过

程为：① 首先利用上一时刻的外部状态 h_{t-1} 和当前时刻的输入 x_t ，计算出三个门 i_t, f_t, o_t ，以及候选状态 c_t ；② 结合遗忘门 f_t 和输入门 i_t 来更新记忆单元 c_t ；③ 结合输出门 o_t ，将内部状态的信息传递给外部状态 h_t 。通过 LSTM 循环单元，整个网络可以建立较长距离的时序依赖关系。

图 1 LSTM 结构图

1.2 空间卷积长短时记忆网络

通过传感器采集到的数据通常为高采样率的时序数据，具有明显的空间的局部和时间的依赖特性。由于 FC-LSTM 内部的连接方式为全连接，其无法分析每个时间步采样数据的空间特性，同时由于参数过多，也会带来严重的信息冗余。为了分析时空特性的数据，SHI^[17]在 FC-LSTM 的基础上，用卷积运算替换 FC-LSTM 的 input-to-state 和 state-to-state 的点乘运算（如图 2 所示），最终形成 LSTM 融合 CNN 的一种空间卷积 LSTM 模型（ConvLSTM 单元），其具体公式如下

$$i_t = \sigma(W_{xi} * x_t + W_{hi} * h_{t-1} + b_i) \quad (6)$$

$$f_t = \sigma(W_{xf} * x_t + W_{hf} * h_{t-1} + b_f) \quad (7)$$

$$o_t = \sigma(W_{xo} * x_t + W_{ho} * h_{t-1} + b_o) \quad (8)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc} * x_t + W_{hc} * h_{t-1} + b_c) \quad (9)$$

$$h_t = o_t \odot \tanh(c_t) \quad (10)$$

式中，* 代表卷积操作算子；其余参数和 FC-LSTM 中的参数相同。

图 2 ConvLSTM 内部结构

2 基于 ConvLSTM 的健康指标模型

基于 ConvLSTM 网络构建 ConvLSTM-HI 模型，该模型结合了 CNN 的局部特征的提取能力和 LSTM 时间依赖性分析能力，尤其适合振动信号等高采样率的连续采样信号，可直接以原始信号作为模型输入，通过堆叠多层网络，自动实现特征降维和健康指标输出。由于该模型为监督式模型，在训练阶段需要以一对带标记的数据 $\{x_t, y_t\}_{t=1}^T$ 作为训练数据，其中 $x_t \in R^{N \times S}$ 为 S 个时间步长的采样数据，每次采样数据长度为 N ； $y_t \in [0, 1]$ 为在时间 t 对应的性能衰退百分比。模型的损失函数可定义如下

$$C = \frac{1}{2} \sum_{t=0}^T \|y_t - \hat{y}_t\|_2^2 \quad (11)$$

式中， $\hat{y}_t$ 为 ConvLSTM-HI 模型的输出； y_t 为真实的标签值。在该模型中，为了将输出值限制在 (0,1) 区间，最后输出神经元的激活函数为 Sigmoid 函数。所以，该模型的健康指标阈值设为 1，通过预测健康指标是否超过阈值 1，来预测 RUL。

为了实现 RUL 的预测，本文建立了双指数寿命模型。双指数寿命模型被证实是一个有效的 RUL 拟合和预测的模型^[18]，其公式为

$$Y = a \exp(bt) + c \exp(dt) \quad (12)$$

式中， Y 代表设备的健康状态； t 代表时间点； a, b, c, d 为模型参数，该 4 个参数在预测阶段会基于粒子滤波算法进行更新。

该模型建立完成后，即可基于 ConvLSTM-HI 模型输出的健康指标更新双指数寿命模型参数，进而利用粒子滤波算法^[19]实现对 RUL 的预测，具体流程如图 3 所示。

图 3 基于 ConvLSTM-HI 的 RUL 预测框架

3 试验验证

为了验证本文提出的基于 ConvLSTM-HI 的 RUL 预测模型的性能, 在公共数据集——IEEE PHM2012 轴承加速寿命试验数据上, 进行了试验。试验数据来自 PRONOSTIA 试验台, 该试验台能够对轴承在几个小时的时间内完成性能退化试验。数据集包含 3 种工况, 共 17 个轴承, 其中每种工况有两个轴承的数据作为训练数据, 其他轴承数据作为测试数据, 数据情况见表 1 所示。加速度计布置及试验台结构如图 4 所示。试验轴承的转速为 1 800 r/min, 载荷为 4 kN。采样频率为 25.6 kHz。每次采样 0.1 秒, 每间隔 10 秒采样一次。具体试验台和试验的描述见文献[20]。

表 1 数据集

数据集工况	工况 1	工况 2	工况 3
训练集	Bearing1_1	Bearing2_1	Bearing3_1
	Bearing1_2	Bearing2_2	Bearing3_2
	Bearing1_3	Bearing2_3	Bearing3_3
测试集	Bearing1_4	Bearing2_4	Bearing3_4
	Bearing1_5	Bearing2_5	Bearing3_5
	Bearing1_6	Bearing2_6	Bearing3_6
	Bearing1_7	Bearing2_7	Bearing3_7

图 4 试验台结构

针对该振动加速度信号, 基于 ConvLSTM 神经网络, 设计了如下深度 ConvLSTM-HI 网络模型, 具体参数如图 5。网络层数为 8 层, 包含 3 层 ConvLSTM 层, 2 层池化层和 3 层全连接层。输入层为 1 维 2560 点的序列, 为 0.1s 的采样数据长度, 时间步长取 15。第一个 ConvLSTM 层的为大卷积核, 是为了在一维振动信号上以更大的视野提取短时局部特征, 其网络参数通过训练得到的, 可以自动地学习到反应轴承退化过程的有用特征。其余 ConvLSTM 层采用小卷积核, 目的是为了减少网络

的参数, 有助于加深网络, 抑制过拟合。前两层 ConvLSTM 后接了池化层, 可以对特征进一步抽象, 降低网络参数。在最后一层 ConvLSTM 的输出后面设置了 3 层全连接层, 其中最后一层为一个单神经元, 作为输出的健康指标。同时, 在全连接层中, 添加了 Dropout 层, 增强网络的鲁棒性, 防止过拟合。

图 5 ConvLSTM-HI 网络模型结构图

实验室所用计算机配置如下: 处理器为 Intel® Core i7-6700 @ 3.4 GHz, 内存为 16 GB, GPU 为 Nvidia® GeForce 1070(8GB); 操作系统为 Microsoft® Windows 10 (64 位); 程序语言为 Python™ 3.6.2(64 位), 基于 TensorFlow-GPU 1.7.0 深度学习框架实现。

试验共 3 个工况, 每个工况 2 组训练数据, 经过 ConvLSTM 模型训练后, 输出的 HI 如图 6a 所示。图 6b 为参考文献[13], 利用时频域特征指标基于 SOM 网络模型输出的 HI 指标。图 6c 为基于 CNN 模型生成的 HI 指标。经过对比可以发现, 因工况的不同造成对应时频域特征指标的范围相异, 所以 SOM-HI 输出的健康指标在 0.7~1.8 之间不等, 这就给阈值的确定造成了困难。然而, 通过 ConvLSTM-HI 模型构建出的健康指标的失效阈值保持在 1。

而且, 从整体上看, 基于 ConvLSTM 网络构建

的健康指标趋势性、单调性和鲁棒性要优于对比方法。进一步,对健康指标的趋势性 $Corr$ 、单调性 Mon 和鲁棒性 Rob 进行定量对比分析。采用的公式如下^[12]

$$Corr = \frac{\left| K \sum_k HI_T(t_k) t_k - \sum_k HI_T(t_k) \sum_k t_k \right|}{\sqrt{\left[K \sum_k HI_T(t_k)^2 - \left(\sum_k HI_T(t_k) \right)^2 \right] \left[K \sum_k t_k^2 - \left(\sum_k t_k \right)^2 \right]}} \quad (13)$$

$$Mon = \frac{1}{2(K-1)} \left| \sum_k \delta(HI_T(t_{k+1}) - HI_T(t_k)) - \sum_k \delta(HI_T(t_k) - HI_T(t_{k+1})) \right| \quad (14)$$

$$Rob = \frac{1}{K} \sum_k \exp \left(- \left| \frac{HI_R(t_k)}{HI(t_k)} \right| \right) \quad (15)$$

式中, HI 为计算得到的健康指标; HI_T 为健康指标趋势项; HI_R 为健康指标残差项; $\delta(\cdot)$ 为单位阶跃函数。

健康指标的趋势性、单调性和鲁棒性计算结果如表2所示。结果表明基于 ConvLSTM 网络构建的健康指标具有更优的趋势性、单调性和鲁棒性。

表2 健康指标的趋势性、单调性和鲁棒性计算

训练集	ConvLSTM-HI			SOM-HI			CNN-HI		
	$Corr$	Mon	Rob	$Corr$	Mon	Rob	$Corr$	Mon	Rob
1_1	0.97	0.52	0.98	0.96	0.28	0.92	0.93	0.54	0.97
1_2	0.99	0.65	0.98	0.98	0.45	0.93	0.96	0.75	0.92
2_1	0.99	0.94	0.99	0.99	0.55	0.96	0.98	0.78	0.93
2_2	0.99	1.00	0.98	0.98	0.58	0.98	0.98	0.84	0.97
3_1	0.99	1.00	0.99	0.97	0.54	0.96	0.99	0.86	0.87
3_2	0.99	0.97	0.99	0.94	0.19	0.95	0.99	0.67	0.96
平均	0.987	0.847	0.985	0.970	0.432	0.950	0.972	0.740	0.937

图6 训练轴承数据健康指标

为了进一步分析 ConvLSTM 网络模型所提取的隐藏特征,利用 t-SNE 算法对网络模型中提取的隐藏层特征进行三维可视化分析。以训练数据 Bearing1_1 为例,其时域图形如图7,由于其为全寿命数据,在寿命末期,随着损伤的不断加剧,振动幅值会明显增大,呈现发散的趋势。对神经网络所提取的特征进行分析,提取的特征层数分别为输入层、第一层池化层、第一层全连接层、第二层全连接层,结果如图8。图8中每个点代表不同时刻 t 下的特征分布,点的颜色代表该点的健康指标,由

图7 Bearing1_1 时域信号

图 8 t-SNE 降维可视化隐藏层特征

图中可以发现,随着网络层数的深入,所提取特征由输入层的混乱无序逐渐向有序转变,能够反映出轴承的退化过程。

利用 ConvLSTM-HI 模型计算出健康指标后,基于本文提出的 RUL 预测框架,可以计算出各测试集的 RUL 预测值。以编号为 Bearing1_3 为例,其预测结果如图 9 所示。图 9a 为本文提出的基于 ConvLSTM-HI 指标的 RUL 预测结果,可发现其在周期数为 2 181 时,达到阈值 1,故其预测的 RUL 为 $2\ 181 - 1\ 801 = 380(10\text{ s})$;在 95% 的置信区间 (Confidence Interval, CI) 下,达到阈值 1 的上下周期区间为 $[2\ 102, 2\ 268]$,预测的 RUL 区间为 $[301, 469](10\text{ s})$ 。图 9b 为利用 SOM-HI 指标进行的 RUL 预测结果,可知其预测的 RUL 为 $1\ 931 - 1\ 801 = 130(10\text{ s})$;图 9c 为利用 CNN-HI 指标进行的 RUL 预测结果,可知其预测的 RUL 为 $2\ 096 - 1\ 801 = 295(10\text{ s})$,准确度均低于本文提出方法。

(a) 基于本文ConvLSTM-HI模型

(b) 基于SOM-HI模型

(c) 基于CNN-HI模型

图 9 轴承 Bearing1_3 的 RUL 预测结果

其他测试集结果见表 3 所示,结果包含了 SOM-HI 模型的预测结果。为了评估两种模型的预测表现,用一个误差百分比指标来进行表示,该指标定义如下

$$Er_i = \frac{ActRUL_i - RUL_i}{ActRUL_i} \times 100\% \quad (16)$$

式中, $ActRUL_i$ 和 RUL_i 为第 i 组试验数据的真实和预测 RUL。

表 3 RUL 预测结果

测试集	当前时刻/(10 s)	真实寿命/(10 s)	预测寿命/(10 s)	本文方法 (%)	SOM-HI (%)	CNN-HI (%)
Bearing1_3	1 801	573	380	33.68	77.31	48.52
Bearing1_4	1 138	290	153	47.24	63.18	53.57
Bearing1_5	2 301	161	212	-31.68	-23.43	-37.91
Bearing1_6	2 301	146	112	23.28	17.15	19.39
Bearing1_7	1 501	757	782	-3.30	19.61	16.27
Bearing2_3	1 201	753	1000	-32.80	41.17	35.84
Bearing2_4	611	139	207	-48.92	39.54	-33.26
Bearing2_5	2 001	309	432	-39.80	48.23	56.13
Bearing2_6	571	129	118	8.52	26.37	-18.65
Bearing2_7	171	58	71	-22.41	-39.12	-65.24
Bearing3_3	351	82	76	7.32	12.84	8.36
绝对误差均值 Er				27.18	37.09	35.74

通过与 SOM-HI、CNN-HI 方法对比,可知基于 ConvLSTM-HI 方法的具有更低的误差率,证明了该模型的优越性。

4 结 论

健康指标构建的准确性直接影响轴承剩余寿命预测的精确度。本文提出了一种 ConvLSTM-HI 的构建模型,可直接从原始振动信号自动提取特征,解决了人工指标选取的先验性依赖;并结合粒子滤波估计和双指数寿命模型,给出了相应的剩余寿命预测框架。通过试验及分析,得到以下结论。

(1) 提出基于空间卷积长短时记忆神经网络的健康指标构建模型。该模型利用卷积神经网络的局部特征提取能力和长短时记忆网络的时间依赖特性,直接从原始信号中挖掘反映设备退化性能的特征,通过深度网络的堆叠,直接输出轴承的健康指标,可实现高维原始数据向低维特征的映射转化,并利用 Sigmoid 函数将其区间控制在 $[0,1]$,便于阈值指标的确定。

(2) 通过与基于人工选择时频域指标的 SOM-HI 和 CNN-HI 对比,本文提出方法构建的健康指标具有更好的趋势性、单调性和鲁棒性,基于该健康指标进行的轴承剩余寿命预测的误差率也更低,对于轴承健康评估和剩余寿命预测具有重要的参考价值。

参 考 文 献

- [1] MOGHADDASS R, ZUO M J. An integrated framework for online diagnostic and prognostic health monitoring using a multistate deterioration process[J]. Reliability Engineering and System Safety, 2014, 124: 92-104.
- [2] QIAO W, ZHANG P, CHOW M Y. Condition monitoring, diagnosis, prognosis, and health management for wind energy conversion systems[J]. IEEE Transactions on Industrial Electronics, 2015, 62(10): 6533-6535.
- [3] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104. LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [4] ZIO E, MAIO F D, STASI M. A data-driven fuzzy approach for predicting the remaining useful life in dynamic failure scenarios of a nuclear system[J]. Reliability Engineering & System Safety, 2010, 95(1): 49-57.
- [5] HENG A, ZHANG S, TAN A C C, et al. Rotating machinery prognostics: State of the art, challenges and opportunities[J]. Mechanical Systems and Signal Processing, 2009, 23(3): 724-739.
- [6] 裴洪, 胡昌华, 司小胜, 等. 基于机器学习的设备剩余寿命预测方法综述[J]. 机械工程学报, 2019, 10(5): 1-13. PEI Hong, HU Changhua, SI Xiaosheng, et al. Review of machine learning based remaining useful life prediction methods for equipment[J]. Journal of Mechanical Engineering, 2019, 10(5): 1-13.
- [7] PAVLE B, MATEJ G, DEJAN P, et al. Bearing fault prognostics using Rényi entropy based features and Gaussian process models[J]. Mechanical Systems and Signal Processing, 2015, 52-53: 327-337.
- [8] MOSTAFA R, REZA A M, HAMED A. Application of dispersion entropy to status characterization of rotary machines[J]. Journal of Sound and Vibration, 2019, 438: 291-308.
- [9] WANG D, TSE P W. Prognostics of slurry pumps based on a moving-average wear degradation index and a general sequential Monte Carlo method[J]. Mechanical Systems and Signal Processing, 2015, 56-57: 213-229.
- [10] YU J. Bearing performance degradation assessment using locality preserving projections and Gaussian mixture models[J]. Mechanical Systems & Signal Processing, 2011, 25(7): 2573-2588.
- [11] YU J. Adaptive hidden Markov model-based online learning framework for bearing faulty detection and performance degradation monitoring[J]. Mechanical Systems & Signal Processing, 2017, 83: 149-162.
- [12] 余道明, 贾民平, 张菀. 一种新型深度自编码网络的滚动轴承健康评估方法[J]. 东南大学学报, 2018, 48(5): 24-29. SHE Daoming, JIA Minping, ZHANG Wan. Deep auto-encoder network method for health assessment of rolling bearings[J]. Journal of Southeast University, 2018, 48(5): 24-29.
- [13] HONG S, ZHOU Z, ZIO E, et al. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method[J]. Digital Signal Processing, 2014, 27: 159-166.

- [14] GUO L, LI N, JIA F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. *Neurocomputing*, 2017, 240: 98-109.
- [15] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: Continual prediction with LSTM[J]. *Neural Computation*, 2000, 12(10): 2451-2471.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [17] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[C]//*Advances in Neural Information Processing Systems*. 2015: 802-810.
- [18] JIN X, SUN Y, QUE Z, et al. Anomaly detection and fault prognosis for bearings[J]. *IEEE Transactions on Instrumentation and Measurement*, 2016, 65(9): 2046-2054.
- [19] QIAN Y, YAN R. Remaining useful life prediction of rolling bearings using an enhanced particle filter[J]. *IEEE Transactions on Instrumentation and Measurement*, 2015, 64(10): 2696-2707.
- [20] NECTOUX P, GOURIVEAU R, MEDJAHED K, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests[C]//*IEEE International Conference on Prognostics and Health Management, PHM'12*. IEEE Catalog Number: CPF12PHM-CDR, 2012: 1-8.

作者简介：王久健，男，1990 年出生，博士研究生。主要研究方向为机械设备状态监测和剩余寿命预测。

E-mail: wangjiujian@hnu.edu.cn

杨绍普(通信作者)，男，1962 年出生，博士，教授，博士研究生导师。主要研究方向车辆系统动力学与控制、非线性系统动力学理论与应用、振动与噪声控制、交通环境与安全工程。

E-mail: yangsp@stdu.edu.cn