

零寿命标签下退化设备剩余寿命预测方法

裴 洪, 司小胜, 胡昌华, 郑建飞, 张建勋, 董 青

(火箭军工程大学控制工程系, 陕西西安 710025)

摘 要: 考虑到安全性与经济性因素, 同类历史设备的性能退化数据大多属于截尾型, 采用深度学习训练时往往面临零寿命标签的挑战, 量化剩余寿命(Remaining Useful Life, RUL)不确定性更是难上加难, 并且现有深度学习模型进行RUL预测时忽略了首达与非首达时间意义之间的区别. 为了克服以上困难, 本文提出一种零寿命标签下退化设备RUL预测方法, 采用数据预处理技术生成以退化信息为标签的样本, 利用贝叶斯双向长短期记忆(Bayesian Bidirectional Long Short-Term Memory, B-Bi-LSTM)模型描述设备性能退化演变规律, 同时借助变分推断技术实现了性能退化的不确定性度量. 进一步, 从可靠性角度分析了性能退化预测分布与RUL分布间的关系, 分别围绕首达与非首达两类情形推导设备RUL概率分布, 通过锂电池案例对所提方法进行实例验证. 实验结果表明, 所提方法能够提供RUL预测的点估计与概率分布式结果, 有效确保了预测结果的科学性.

关键词: 剩余寿命预测; 零寿命标签; 贝叶斯双向长短期记忆模型; 退化设备; 首达时间; 非首达时间

基金项目: 国家自然科学基金(No.62103433, No.62233017, No.62227814, No.62073336)

中图分类号: TP18; TB114.3; V239 **文献标识码:** A **文章编号:** 0372-2112(2023)07-1939-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221201

Prognostic Method of Remaining Useful Life for Degraded Equipment Under Zero Life Label

PEI Hong, SI Xiao-sheng, HU Chang-hua, ZHENG Jian-fei, ZHANG Jian-xun, DONG Qing

(Department of Automation, Rocket Force University of Engineering, Xi'an, Shaanxi 710025, China)

Abstract: Considering the safety and economic factors, most of the performance degradation data of historical equipment are truncated type. The challenge of zero life label is encountered when deep learning training is adopted, quantifying the uncertainty of remaining useful life (RUL) is even more difficult, and what is more, the existing deep learning models ignore the difference between the first hitting and non-first hitting time meanings when predicting the RUL. To overcome the above difficulties, this paper proposes a method over RUL prediction for degraded equipment under zero life label. Data preprocessing technology is utilized to generate samples labeled with degradation information, and the evolution law of equipment performance degradation is described by Bayesian bidirectional long short-term memory (B-Bi-LSTM) model. At the same time, the uncertainty measurement of performance degradation is realized by means of variational inference technology. Furthermore, the relationship between the performance degradation prediction distribution and the RUL distribution is analyzed from the perspective of reliability, and the RUL probability distribution of the equipment is derived from the point of the first hitting and non-first hitting time respectively. The proposed method is verified by a case of lithium battery. The experimental results show that the proposed method can provide the point estimation and probability distribution results of RUL prediction, which can effectively ensure the scientificity of the prediction results.

Key words: remaining useful life prediction; zero life label; Bayesian bidirectional long short-term memory model; degraded equipment; first hitting time; non-first hitting time

Foundation Item(s): National Natural Science Foundation of China (No.62103433, No.62233017, No.62227814, No.62073336)

1 引言

工程设备的复杂化、智能化、自动化程度日益提高对其安全性与可靠性提出了越来越高的要求^[1,2]. 剩余寿命(Remaining Useful Life, RUL)预测技术通过分析测试数据,挖掘出设备性能演变规律,进而决断出设备还能正常运行时间,近年来受到了国内外研究学者的普遍关注^[3-8].

当前,深度学习技术已广泛应用于设备RUL预测领域^[2,4,8]. 从有无训练标签的视角来看,基于深度学习的预测方法主要有两种思路:基于健康指标的方法^[9,10]与基于标签的方法^[11-14]. 基于标签的方法可看作有监督训练的回归问题,能够将特征提取与RUL预测整合为统一模型,因而能够有效节约时间成本,克服基于健康指标方法的弊端.

现有基于深度学习RUL预测的主要挑战在于量化RUL不确定性. 针对该问题,Bayesian神经网络应运而生^[15,16],并且逐步应用于RUL预测^[17-20]. 然而,此类深度学习预测模型需提前获得寿命信息才能构建相应的RUL标签数据. 因此,当面对截尾数据时,无法直接获取到寿命信息,即面临零寿命标签问题,上述预测模型适用性受到了严重限制. 尽作者所知,以退化信息为标签的预测模型虽能处理截尾退化数据,但基于该模型的RUL不确定性量化研究极其匮乏. 此外,现有深度学习模型进行RUL预测时忽略了首达与非首达时间意义之间的区别,不利于预测精度的提升.

长短期记忆模型(Long Short-Term Memory, LSTM)常用于以退化信息为标签的预测模型,为考虑当前测试数据与未来测试数据间的关系,双向长短期记忆模型(Bidirectional Long Short-Term Memory, Bi-LSTM)得到了重点关注. 基于此,本文融入Bayesian神经网络思想形成性能退化不确定性表征模型,即贝叶斯双向长短期记忆(Bayesian Bidirectional Long Short-Term Memory, B-Bi-LSTM). 本文的工作重点在于提出一种零寿命标签下退化设备RUL预测方法.

2 数据预处理

由于运行过程中监测的时序数据可能量纲不一致,给RUL预测带来极大挑战,有必要采用归一化技术将所得测试数据按照某种规则变换至统一尺度下,能够有效提高RUL预测精度. 此外,现实中零寿命标签问题难以直接应用以RUL为标签的预测模型,需要借助于滑动时间窗重新生成标签进行训练^[21]. 因此,本节将重点介绍归一化处理与滑动时间窗技术的具体实现过程.

2.1 归一化处理

根据现有文献能够发现,min-max归一化和z-score归一化是两种常见的归一化方法. 前者是将获取的测

试数据进行线性变换,将变换后的结果限定在 $[0, 1]$ 范围内,相应的转换函数可表示为

$$x'_{i,j} = \frac{x_{i,j} - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (1)$$

式中, $x_{i,j}$ 为第*i*组退化系统的第*j*个原始测试数据, $x_{i,\min}$ 与 $x_{i,\max}$ 分别表示第*i*组退化系统原始测试数据的最小值和最大值. $x'_{i,j}$ 表示第*i*组退化系统归一化后的测试数据.

后者能够确保标准化后的数据服从标准正态分布,通过将原始测试数据减去总体平均值,然后将差值除以总体标准偏差进行计算. 具体公式可表示为

$$x'_{i,j} = \frac{x_{i,j} - \mu_i}{\sigma_i} \quad (2)$$

其中, μ_i 为第*i*组退化系统总体测试数据的均值, σ_i 代表相应的总体标准偏差. 除非另外说明,否则后续推导中,为方便符号的简化,归一化后的测试数据 $x'_{i,j}$ 均由符号 $x_{i,j}$ 表示.

2.2 滑动时间窗处理

滑动时间窗处理技术不仅可以将原始时间序列数据转换为所需的序列数据,而且能够保留原始时间序列数据的局部依赖性. 因而这项技术广泛用于生成训练深度学习所需的数据集. 具体地,将连续的测试数据封装在固定长度的时间窗内,然后该时间窗通常每次均沿时间轴向前滑动一个检测步长. 图1描述了现场退化系统历史数据的滑动时间窗处理结果,其中,现场退化设备的历史测试数据表示为 $\{x_1, x_2, \dots, x_N\}$,数据数目用*N*表示,从第一个数据开始,以*d*为时间窗长度封装测试数据,并将时间窗每次向前滑动一个步长形成多个训练样本.




图1 现场退化设备历史数据滑动时间窗处理结果

从图中可以看出,特定时间窗内的连续测试数据可视为一个训练样本,通过将其输入至所提深度学习模型中以训练模型的参数. 注意到,每个时间窗的固定长度可用*d*表示,标签为时间序列数据中*L*步之后的性能退化水平. 现有文献已经证实,较长的时间窗能够在一定程度上保留更多的局部特征. 但随着时间窗长度

的增加,模型训练的效率将会受到严重影响.

3 基于B-Bi-LSTM的性能退化预测模型

3.1 Bi-LSTM模型

由于RNN在时间序列数据分析方面的优势,本文自然考虑采用RNN作为候选模型.但当处理长时间序列数据时,RNN训练过程不可避免会出现记忆损失的问题,具体表现为RNN仅对近期输入信息存在较深的记忆,但对较早之前的输入信息不再敏感,这类固有缺陷将会引发反向传播时梯度消失或者梯度爆炸的问题.针对上述缺陷,学者们提出了LSTM对其改进.图2绘制了LSTM记忆单元结构示意图.可以看出,LSTM的记忆单元主要包含遗忘门、输入门以及输出门三部分.

具体数学模型可表示为^[22,23]

$$\begin{aligned} f_t &= \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f) \\ i_t &= \sigma(W_{ih}h_{t-1} + W_{ix}x_t + b_i) \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ o_t &= \sigma(W_{oh}h_{t-1} + W_{ox}x_t + b_o) \\ h_t &= o_t \odot \tanh(c_t) \end{aligned} \quad (3)$$




图2 LSTM记忆单元示意图

传统意义的LSTM仅考虑了当前测试数据与先前测试数据之间的关系,但忽略了当前测试数据与未来测试数据间的关系.在实际工程中,收集的时间序列数据具有极强的时间依赖性,充分考虑未来信息与当前时刻数据的关系是必要且有意义的.现有研究已经证实,Bi-LSTM能够沿着两个时间方向处理输入时间序列,正时间方向的序列数据输入至前向层,而负时间方向的序列数据输入至后向层,因而Bi-LSTM能够以前向与后向两种方式捕获动态依赖性,已在现有文献得到广泛应用.具体可表示为:

最后一个前向层的输出状态 \vec{h}_t^{out} 与最后一个后向层的输出状态 $\overleftarrow{h}_t^{\text{out}}$ 可连接为 $\mathbf{h} = \left(\vec{h}_t^{\text{out}}, \overleftarrow{h}_t^{\text{out}} \right)_{t=1}^{P_0}$, 中, P_0 为每个训练样本的时间步长.连接后的向量需要通过一个全连接层作进一步的处理,因此,全连接层的输出可作为输入序列的高水平表示,具体可表示为

表1 Bi-LSTM的数学描述

方向	表达式
前向	$\vec{f}_t^L = \sigma(W_{fh}^L \vec{h}_{t-1}^L + W_{fx}^L \vec{h}_t^{L-1} + \vec{b}_f^L)$
	$\vec{i}_t^L = \sigma(W_{ih}^L \vec{h}_{t-1}^L + W_{ix}^L \vec{h}_t^{L-1} + \vec{b}_i^L)$
	$\vec{o}_t^L = \sigma(W_{oh}^L \vec{h}_{t-1}^L + W_{ox}^L \vec{h}_t^{L-1} + \vec{b}_o^L)$
	$\vec{c}_t^L = \tanh(W_{ch}^L \vec{h}_{t-1}^L + W_{cx}^L \vec{h}_t^{L-1} + \vec{b}_c^L)$
	$\vec{c}_t^L = \vec{f}_t^L \odot \vec{c}_{t-1}^L + \vec{i}_t^L \odot \vec{c}_t^L$
	$\vec{h}_t^L = \vec{o}_t^L \odot \tanh(\vec{c}_t^L)$
后向	$\overleftarrow{f}_t^L = \sigma(W_{fh}^L \overleftarrow{h}_{t+1}^L + W_{fx}^L \overleftarrow{h}_t^{L-1} + \vec{b}_f^L)$
	$\overleftarrow{i}_t^L = \sigma(W_{ih}^L \overleftarrow{h}_{t+1}^L + W_{ix}^L \overleftarrow{h}_t^{L-1} + \vec{b}_i^L)$
	$\overleftarrow{o}_t^L = \sigma(W_{oh}^L \overleftarrow{h}_{t+1}^L + W_{ox}^L \overleftarrow{h}_t^{L-1} + \vec{b}_o^L)$
	$\overleftarrow{c}_t^L = \tanh(W_{ch}^L \overleftarrow{h}_{t+1}^L + W_{cx}^L \overleftarrow{h}_t^{L-1} + \vec{b}_c^L)$
	$\overleftarrow{c}_t^L = \overleftarrow{f}_t^L \odot \overleftarrow{c}_{t+1}^L + \overleftarrow{i}_t^L \odot \overleftarrow{c}_t^L$
	$\overleftarrow{h}_t^L = \overleftarrow{o}_t^L \odot \tanh(\overleftarrow{c}_t^L)$

$$\hat{y} = \sigma(\mathbf{W}_{hy} \mathbf{h} + \mathbf{b}_y) \quad (4)$$

式中, \mathbf{W}_{hy} 与 \mathbf{b}_y 分别表示全连接层的权重与偏置.需要注意的是,这里的输出结果为点估计,无法对不确定性进行度量.

3.2 性能退化预测不确定量化

工程实践表明,对Bi-LSTM输出预测结果的不确定性进行度量对于保障工程退化系统可靠性与安全性具有重要意义.为实现该目标,将Bayesian神经网络的思想融入至Bi-LSTM中,即B-Bi-LSTM.主要思路是Bi-LSTM的网络参数可视为服从某种分布的随机变量用于描述预测不确定性.根据双向结构特性,随机变量 ω 可分为三部分:前向层的权重与偏置 $\omega_{fw} = \left\{ \vec{\mathbf{W}}_i, \vec{\mathbf{b}}_i \right\}_{i=1}^{N_{fw}}$,

后向层的权重与偏置 $\omega_{bw} = \left\{ \overleftarrow{\mathbf{W}}_i, \overleftarrow{\mathbf{b}}_i \right\}_{i=1}^{N_{bw}}$ 以及回归层的权重与偏置 $\omega_{rg} = \left\{ \mathbf{W}_{hy}, \mathbf{b}_y \right\}$. 其中, $\vec{\mathbf{W}}_i$ 与 $\vec{\mathbf{b}}_i$ 分别表示第 i 个前向层全部权重与偏置,而 $\overleftarrow{\mathbf{W}}_i$ 与 $\overleftarrow{\mathbf{b}}_i$ 分别表示第 i 个后向层全部权重与偏置. N_{fw} 与 N_{bw} 分别表示前向层与后向层的总数目.采用滑动时间窗处理技术,训练数据集可表示为输入 $X_d = \left\{ \mathbf{x}_d^m \right\}_{m=1}^M$ 与相应退化标签 $x_{d+L} = \left\{ x_{d+L}^m \right\}_{m=1}^M$, 其中, \mathbf{x}_d^m 与 x_{d+L}^m 分别表示第 m 个训练样本的输入与退化标签,并且 M 表示训练样本的总数目.

基于Bayesian定理,能够对深度学习模型参数 ω 的后验分布进行在线更新,更新结果可表示为

$$\begin{aligned} p(\omega | X_d, x_{d+L}) &= \frac{p(x_{d+L} | X_d, \omega) p(\omega)}{p(x_{d+L} | X_d)} \\ &= \frac{p(x_{d+L} | X_d, \omega) p(\omega)}{\int p(x_{d+L} | X_d, \omega) p(\omega) d\omega} \end{aligned} \quad (5)$$

根据式(5)中的更新结果,当输入一个新的测试样本 \mathbf{x}_d^* ,可进一步得到未来 L 步的性能退化预测分布,即

$$p(\mathbf{x}_{d+L}^* | \mathbf{x}_d^*, X_d, x_{d+L}) = \int p(\mathbf{x}_{d+L}^* | \mathbf{x}_d^*, \omega) p(\omega | X_d, x_{d+L}) d\omega \quad (6)$$

后验分布计算的主要任务为求解关于 ω 的边沿似然函数 $p(\mathbf{x}_{d+L} | X_d)$,在实际中对于复杂的网络结构是难以处理的,进而将直接影响到后验分布闭式表达式的推导.因而,采用变分推断技术通过变分分布来近似模型参数的后验分布 $p(\omega | X_d, x_{d+L})$.通过最小化近似变分分布 $q(\omega)$ 与后验分布 $p(\omega | X_d, x_{d+L})$ 间的 Kullback-Leibler(KL)散度,以确定最优变分分布. KL 散度是一种度量两种分布相似性的指标,可计算为

$$\begin{aligned} \ell &= \text{KL}(q(\omega) \| p(\omega | X_d, x_{d+L})) \\ &= - \int q(\omega) \log p(\mathbf{x}_{d+L} | X_d, \omega) d\omega \\ &\quad + \text{KL}(q(\omega) \| p(\omega)) + \log(p(\mathbf{x}_{d+L} | X_d)) \quad (7) \\ &= - \sum_{m=1}^M \int q(\omega) \log p(\mathbf{x}_{d+L}^m | \mathbf{x}_d^m, \omega) d\omega \\ &\quad + \text{KL}(q(\omega) \| p(\omega)) + \text{const} \end{aligned}$$

式(7)中的 KL 散度主要包含三部分.第一部分为关于 $q(\omega)$ 的期望对数似然函数,通过最大化这部分能够使 $q(\omega)$ 更好解释训练样本;第二部分为 $q(\omega)$ 与 $p(\omega)$ 的 KL 散度,最小化该部分能够确保 $q(\omega)$ 更加接近先验分布;第三部分与 $q(\omega)$ 并无关系,因而在执行变分推断过程中可替换为常值.自然地,最小化 KL 散度过程中只需研究前两部分即可,式(7)中的 KL 散度可进一步写为

$$\ell \propto - \sum_{m=1}^M \int q(\omega) \log p(\mathbf{x}_{d+L}^m | \mathbf{x}_d^m, \omega) d\omega + \text{KL}(q(\omega) \| p(\omega)) \quad (8)$$

通过子采样策略与重参数化技术可有效解决计算庞大和高维积分问题,相应的能够确定出近似 KL 散度,即

$$\begin{aligned} \hat{\ell}_{\text{MC-GP}} &= - \frac{M}{J} \log p(\mathbf{x}_{d+L}^m | \mathbf{x}_d^m, \hat{\omega}^m) \\ &\quad + \sum_{h=1}^H \left[\frac{p^h c^2}{2} \|\boldsymbol{\mu}_w^h\|_2^2 + \frac{c^2}{2} \|\boldsymbol{\mu}_b^h\|_2^2 \right] \\ &= \frac{1}{J} \sum_{m \in S} - \frac{\log p(\mathbf{x}_{d+L}^m | \mathbf{x}_d^m, \hat{\omega}^m)}{\tau} \\ &\quad + \sum_{h=1}^H \left[\frac{p^h c^2}{2\tau M} \|\boldsymbol{\mu}_w^h\|_2^2 + \frac{c^2}{2\tau M} \|\boldsymbol{\mu}_b^h\|_2^2 \right] \quad (9) \\ &= \frac{1}{J} E(\mathbf{x}_{d+L}^m, \hat{\mathbf{x}}_{d+L}^m(\mathbf{x}_d^m, \hat{\omega}^m)) \\ &\quad + \sum_{h=1}^H \left[\frac{p^h c^2}{2\tau M} \|\boldsymbol{\mu}_w^h\|_2^2 + \frac{c^2}{2\tau M} \|\boldsymbol{\mu}_b^h\|_2^2 \right] \end{aligned}$$

通过式(9)可以发现,该目标函数与 Dropout 下的目标函数具有一定相似性.现有文献已证明,基于变分推断的 B-Bi-LSTM 与 Dropout 技术作用的传统 Bi-LSTM 在特定条件下具有一定的等价关系.因此,将式(6)中模型参数后验分布替换为获得的最优变分分布,则当输入一个新的测试样本 \mathbf{x}_d^* ,未来 L 步性能退化预测分布可执行为

$$\begin{aligned} p(\mathbf{x}_{d+L}^* | \mathbf{x}_d^*, X_d, x_{d+L}) &\approx \int p(\mathbf{x}_{d+L}^* | \mathbf{x}_d^*, \omega) q^*(\omega) d\omega \\ &\approx \frac{1}{V} \sum_{v=1}^V p(\mathbf{x}_{d+L}^* | \mathbf{x}_d^*, \hat{\omega}_v) \quad (10) \end{aligned}$$

4 RUL 分布推导

对于给定测试样本 $\mathbf{x}_d^*, \mathbf{x}_{d+L}^*$ 的单个具体实现值可通过带有 Dropout 技术的深度学习模型进行一次前向传递,相应地, \mathbf{x}_{d+L}^* 的多组实现值,作为预测后验分布多次采样结果,可进行多重随机前向传递获取到.当采样次数足够多时,大量的实现值能够很好反映和拟合未来 L 步的性能退化预测分布.考虑到高斯混合分布能够近似任意连续分布,可作为候选分布用于描述式(10)所定义的后验预测分布,进一步,大量实现值的均值可视作未来 L 步性能退化预测值,以实现对现场退化系统未来退化水平的补充.根据所提滑动时间窗技术,将会生成一个新的测试样本,输出至所提 B-Bi-LSTM 以确定随后的未来 L 步性能退化预测.这类预测-补充过程交替执行,因而未来任意时刻的性能退化分布可通过拟合高斯混合分布进行确定.

现有文献将失效分为两类:软失效与硬失效^[24,25].前者意味着退化系统仍可继续运行,但退化系统性能将无法使用要求;后者亦称为功能性失效,表明退化系统不能继续正常运行.注意到,如无特殊说明,本文所研究的失效均为软失效.即当退化系统的性能指标超过预设的失效阈值时,表明退化系统发生了性能失效.从可靠性理论的基本概念来看,现场退化系统未来任意时刻发生失效的概率能够表示为:

$$P(t_k) = P(x_k > w) = \int_w^{+\infty} p(x_k) dx_k \quad (11)$$

其中, $p(x_k)$ 为拟合后的分布.根据现场退化系统的历史测试数据 \mathbf{x} ,分别以非首达时间与首达时间的两种情形定义设备在 t_N 的 RUL,前者仅关注未来某时刻超出阈值的情形,强调在该时刻之前的退化水平可能会超出阈值,即该时刻并非首次超出阈值;后者在前者基础上,侧重于第一次超出阈值的概念,下面具体分析两类情形.

4.1 非首达情形

当考虑非首达情形时,设备的 RUL 仅与未来特定时刻的退化水平相关,则当前时刻 t_N 的 RUL 可定义为

$$L_N = \{l_N: X(t_N + l_N) \geq w | \mathbf{x}\} \quad (12)$$

其中, $X(t_N + l_N)$ 表示 $t_N + l_N$ 时刻的性能退化. 上述定义建立了性能退化与 RUL 之间关系. 进一步, t_N 时刻 RUL 的累积分布函数 (Cumulative Distribution Function, CDF) 可表示为: $F(l_N) = P(L_N \leq l_N)$. 根据上述 RUL 定义, 式(12)中 CDF 所表示的概率可视为式(11)中 $t_N + l_N$ 时刻的失效概率. 至此, 当前时刻 t_N 的 RUL 的 CDF 能够确定出来, 同时根据 CDF 与概率密度函数 (Probability Density Function, PDF) 间的关系, 可得到相应的 PDF.

4.2 首达情形

在首达时间的意义下, 当前时刻 t_N 的 RUL 可定义为

$$L_N = \inf \{l_N: X(t_N + l_N) \geq w | X(t_N) < w\} \quad (13)$$

其中, \inf 表示下确界因子, $X(t_N + l_N)$ 表示 $t_N + l_N$ 时刻的性能退化.

鉴于预测的未来时刻性能退化为离散监测点下的概率分布, 基于性能退化的 RUL 取值同样为离散值, 因此在首达时间的约束下, 当 RUL 等于 l_N , 意味着设备在 $(t_N + l_N)$ 的退化水平首次超过阈值, 在 $(t_N + 1) \sim (t_N + l_N - 1)$ 之间每个时刻的退化水平均未超出阈值, 则设备 RUL 为 l_N 的概率为

$$P(L_N = l_N) = P(X(t_N + 1) < w \cup \dots \cup X(t_N + l_N - 1) < w \cup X(t_N + l_N) \geq w) \quad (14)$$

一般地, 若直接求解该联合概率密度函数较为复杂, 这里考虑一种特殊情况, 即不同时刻的性能退化相

互独立, 因此式(14)可近似为

$$P(L_N = l_N) \approx (1 - P(t_N)) \dots (1 - P(t_N + l_N - 1)) P(t_N + l_N) \quad (15)$$

根据 RUL 的离散分布概率, 可以进一步将其转化为 RUL 的累积分布函数, 进而可得到 RUL 的概率密度函数, 因此能够实现 RUL 的不确定性量化.

综上所述, 所得 CDF 与 PDF 能够有效度量 RUL 预测不确定性, 对于科学安排维护活动与确保运行安全性具有重要作用和价值.

为了直观理解所提方法的思路, 这里以流程图的形式展示上述过程. 从图 3 可以看出, 基于 B-Bi-LSTM 的性能退化预测主要分为训练阶段与测试阶段, 在训练阶段, 对数据库中历史设备的测试数据和现场设备的历史数据进行预处理, 以产生满足深度学习网络输入要求的训练样本, 基于该训练样本对网络进行训练, 以确定相应的权重与偏置. 需要注意的是, Bayesian 神经网络的思想融入至 Bi-LSTM 学习模型中, 通过变分推断技术获得了权重与偏置的后验分布. 在测试阶段, 可利用训练完成的 B-Bi-LSTM 模型, 确定出未来时刻的性能退化分布, 随后将所得性能退化分布的期望值视为性能退化外推值以进行下一步的性能退化预测. 性能退化预测完成后, 执行 RUL 预测环节, 分两种情形区分 RUL 的定义, 在此基础上通过将未来时刻的失效概率转换为设备 RUL 的 CDF 与 PDF, 进而实现两种情形下 RUL 不确定性的量化, 这种区分可视为所提方法的特色所在, 对于丰富大数据背景下 RUL 预测理论体系具有重要的理论价值.

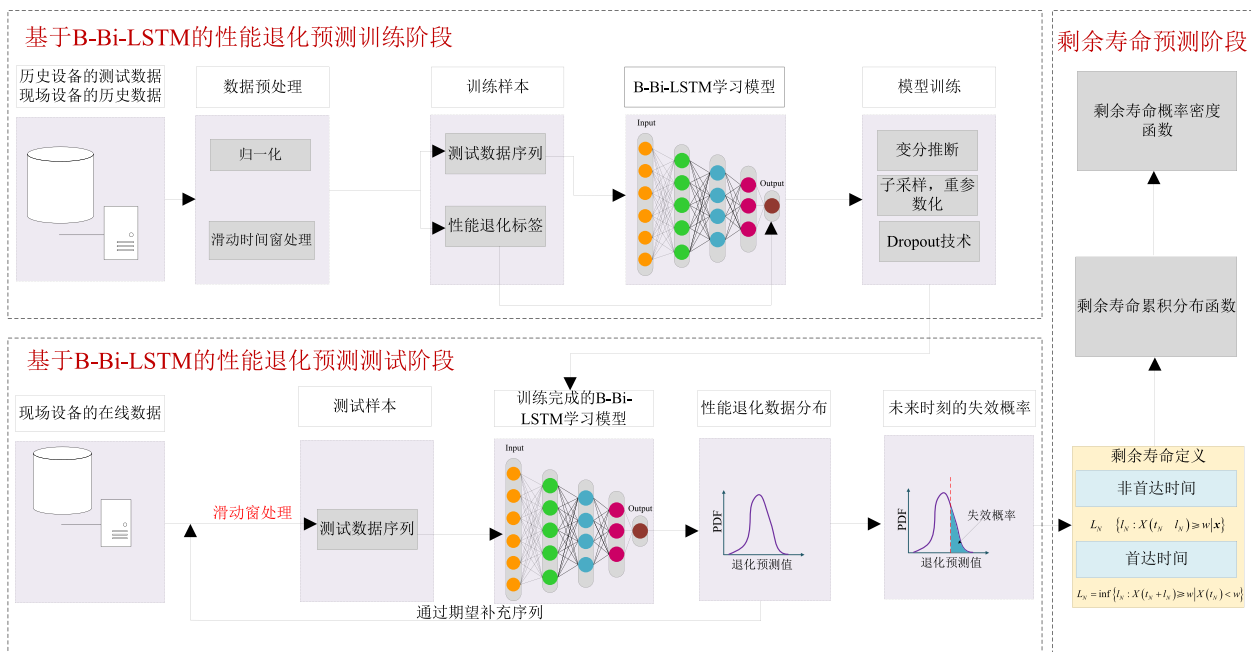


图3 所提方法流程图

5 案例研究

5.1 数据描述与预处理

作为一类重要的能源装置,锂电池广泛应用于包含消费类电子产品、电动汽车,航空航天,军事装备和工业机器人等各种复杂系统.相比于铅酸、镍镉和镍金属氢化物电池,锂电池在功率密度、循环寿命、温度适应性、质量以及环保性等方面具有诸多优势.不可否认,由于连续的充放电循环,锂电池通常会面临性能退化,进而将引起不稳定的运行与不必要的停机.因此,准确预测出锂电池 RUL 为保障上述系统安全可靠运行提供重要的技术支撑.

本文所采用的测试数据为四组 CS2 电池退化数据集(CS2-35, CS2-36, CS2-37 和 CS2-38),数据集由马里兰大学先进寿命周期工程中心(Center for Advanced Life Cycle Engineering, CALCE)提供,并且可在官网工业中心的电池专栏下载^[26].每个 CS2 电池均经历统一的充电模式,即标准的恒定电流/恒定电压协议,具体先以 1C 恒定电流率充电,直到电压达到 4.2 V 然后保持 4.2 V,直至充电电流降至 0.05 A 以下,同时,每个电池的放电截止电压为 2.7 V.据作者所知,容量是评估电池健康状况,判断电池是否需要更换的典型性能指标,因此选择该指标进行锂电池 RUL 预测.图 4 展示了上述四组锂离子的容量曲线.可以看出,容量随着循环和老化将以复杂形式动态衰减,整个衰减过程可明显分为两种不同阶段:慢速退化阶段与快速退化阶段.




图4 四组锂电池的容量变化轨迹

采用文献[27]中的归一化处理方法使容量值分布在 $[0, 1]$ 范围内.随后,利用滑动时间窗口处理技术生成具有固定长度的训练与测试样本.这里假定编号为 CS2-36、CS2-37 和 CS2-38 的电池为历史同类退化系统,而编号为 CS2-35 的电池可被视为现场退化系统.注意到,每个时间窗的固定长度 d 与预测步长 L 可设为 50 与 10.并且,容量的失效阈值设为 0.5,故 CS2-35 电池出现失效是在第 802 个循环.由于寿命周期内初始阶段可

靠性足够大,后期阶段进行 RUL 预测显得比初始阶段更加有必要与价值.本节将 CS2-35 电池截止到 600 个循环获取的容量数据存储于数据库中作为现场退化系统的历史数据.利用 CS2-36、CS2-37 和 CS2-38 电池的完整容量数据以及 CS2-35 截止到 600 个循环获取的容量数据,通过滑动窗处理技术可生成训练样本,而且来自于 CS2-35 的最后 100 个训练样本可视为测试样本以评估网络性能.经历 600 个循环后,需要对 CS2-35 电池进行 RUL 预测并度量预测结果的不确定性.

5.2 模型训练与性能退化不确定性量化

为选择合适的 Bi-LSTM 变体并确定相应的超参数,应该对不同网络参数下的性能退化预测结果进行比较.所有候选网络的迭代次数、样本批量大小、步长、输入长度和 Dropout 率的默认值分别设为 200、200、50、10 和 0.05.通过预训练发现隐藏层为 2~4 时效果最佳,因此本小节从 $\{2, 3, 4\}$ 集合中选择隐藏层的数量,同时从集合 $\{0.000\ 1, 0.000\ 5, 0.000\ 9\}$ 中选择学习率.表 2 罗列出不同候选网络的具体信息,用于预测未来 L 步的性能退化.注意到,这里为方便对比与分析,双向 LSTM 的前向层与对应后向层的神经元数目保持统一.对于特定的网络,采用测试样本的均方误差 (Mean-Squared Error, MSE) 来衡量退化水平预测效果,具体可表示为

$$\text{MSE}_{\text{testing}} = \frac{1}{N_{\text{testing}}} \sum_{k=1}^{N_{\text{testing}}} (\hat{x}_{d+L,k} - x_{d+L,k})^2 \quad (16)$$

其中, N_{testing} 代表测试样本的总数目, $\hat{x}_{d+L,k}$ 与 $x_{d+L,k}$ 表示第 k 个测试样本输出结果与退化标签.训练与测试过程均在配有 Inter Core i7 处理器与 16 GB RAM 的个人计算机上通过 TensorFlow 环境进行编程实现.因而,能够获得不同网络参数下 Bi-LSTM 的测试 MSE 结果,如表 2 所示.

基于表 2 中 Bi-LSTM 的测试 MSE,选择测试 MSE 最小时的 Bi-LSTM 结构参数,具体结构为 32-32-32,学习率为 0.000 9. Bi-LSTM 的超参数确定后,将采用本文所提 Bayesian 深度学习预测方法对锂电池的 RUL 进行预测.选择四个瞬时作为预测时刻,即第 600 个循环、第 650 个循环、第 700 个循环以及第 750 个循环,分别研究这四个预测时刻的性能退化预测与 RUL 预测效果.通过执行 1 000 次随机前向传递,能够获得未来时刻性能退化的 1 000 组实现值,这些实现值可反映出相应的预测分布.进一步,利用 1000 组实现值的均值对现场退化系统未来时刻退化数据进行补充.图 5 给出了四个预测时刻性能退化预测的均值与 95% 置信区间.

从图 5 可以发现,未来时刻性能退化的预测值均围绕真实值在一定范围内上下波动,这种波动性可能是运行过程随机性、环境复杂多变性等多种因素所造成的,尽管性能退化的预测值与真实值之间存在一定的

表 2 不同网络参数下 Bi-LSTM 的测试 MSE

网络类型	超参数			测试MSE
	隐含层数	网络结构	学习率	
双向 LSTM	2	128-128	0.000 1	1.15×10^{-4}
	2	128-128	0.000 5	1.04×10^{-4}
	2	128-128	0.000 9	1.09×10^{-4}
	2	64-64	0.000 1	9.95×10^{-5}
	2	64-64	0.000 5	9.93×10^{-5}
	2	64-64	0.000 9	9.98×10^{-5}
	3	64-64-64	0.000 1	1.06×10^{-4}
	3	64-64-64	0.000 5	1.10×10^{-4}
	3	64-64-64	0.000 9	1.02×10^{-4}
	3	32-32-32	0.000 1	9.98×10^{-5}
	3	32-32-32	0.000 5	9.85×10^{-5}
	3	32-32-32	0.000 9	9.57×10^{-5}
	4	32-32-32-32	0.000 1	1.05×10^{-4}
	4	32-32-32-32	0.000 5	1.00×10^{-4}
	4	32-32-32-32	0.000 9	9.89×10^{-5}
	4	16-16-16-16	0.000 1	9.95×10^{-5}
4	16-16-16-16	0.000 5	9.99×10^{-5}	
4	16-16-16-16	0.000 9	9.86×10^{-5}	

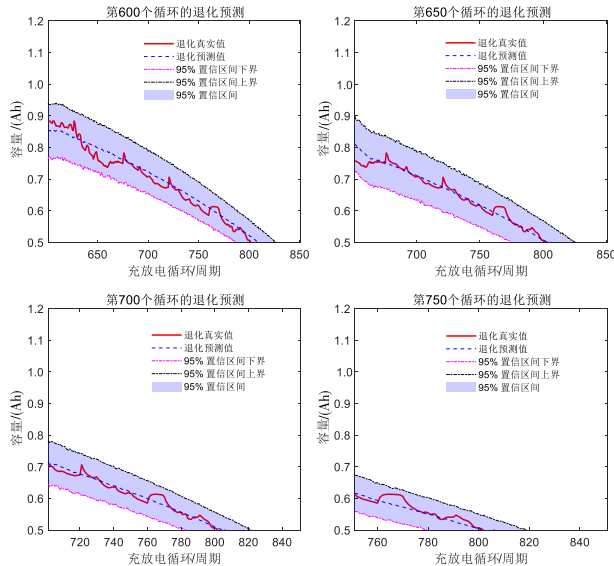


图 5 四个预测时刻性能退化预测的均值与 95% 置信区间

偏差,真实值均能被性能退化预测的 95% 区间所覆盖,进而表明本文所提基于 MC Dropout 的性能退化预测结果能够更加科学合理地刻画出真实的退化路径。

5.3 RUL 预测与敏感性分析

在此基础上,可采用第 4 节定义的非首达时间与首达时间两种情形下的 RUL,以失效率为纽带可得到锂电池在四个预测时刻 RUL 的 PDF 曲线,如图 6 所示。从图中可以直观看出,两类情形下 RUL 的 PDF 曲线均能

覆盖真实 RUL,有效验证了所提方法有效性。并且对于同一预测时刻,两类情形下 PDF 曲线的高度是一致的,意味着首达意义下 RUL 与非首达意义下 RUL 的不确定性是相统一的,这是因为不确定性是由 Dropout 率所决定的。从预测均值的角度来看,非首达意义下 RUL 的预测值更加接近 RUL 真实值,对于 650 循环和 750 循环两个预测时刻,两者几乎重合,但容易存在高估 RUL 的问题。首达意义下 RUL 的预测结果与真实值的偏差相对较大,可能是由于理论推导中近似计算的缘故,但一般都比 RUL 真实值小。若在实际工程中关注的是预测精度,可选择非首达意义下 RUL 结果,若重点在于避免事故发生,可选择首达意义下 RUL 结果。

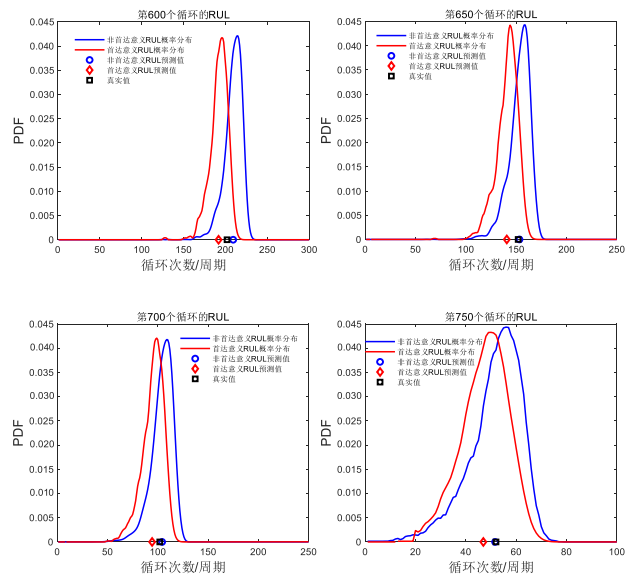


图 6 两类情形下四个预测时刻 RUL 预测结果对比

工程实践表明,性能退化的预测效果对预测步长较为敏感。通常对于不同的预测步长,性能退化的预测效果是有差别的,从而导致不同的 RUL 预测精度。为此以非首达意义下 RUL 为例,研究不同预测步长下的 RUL 预测效果,即分析 RUL 预测效果受到预测步长影响的敏感程度。为了开展敏感性分析,首先,可以将预测步长分别设置为 10、20 和 30。由于预测步骤直接决定性能退化标签,因此应针对不同的预测步长,采用本文所提预处理过程重新制作训练数据集与测试数据集。将特定步长下的数据集输入至 B-Bi-LSTM,用于执行网络训练和性能退化预测。相应地,可计算出不同预测步长下非首达意义的 RUL 预测结果,选择现有文献常用的平均绝对误差 (Mean Absolute Error, MAE) 与准确性分数 (Score Of Accuracy, SOA) 以及 MSE 对预测结果开展深入分析,计算公式如下:

$$MAE_N = \left| \hat{L}_N - L_{true,N} \right| \quad (17)$$

$$SOA_N = \begin{cases} \exp(-\ln(0.5) \cdot (Er_N/5)), & \text{if } Er_N \leq 0 \\ \exp(+\ln(0.5) \cdot (Er_N/20)), & \text{if } Er_N > 0 \end{cases} \quad (18)$$

$$MSE_N = \int_0^{\infty} f(l_N)(l_N - l_{true,N})^2 dl_N \quad (19)$$

其中, N 为截止预测时刻的监测数目, \hat{L}_N 与 $L_{true,N}$ 为在某个预测时刻的预测 RUL 与真实 RUL, Er_N 表示预测 RUL 百分误差, 可计算为 $Er_N = \frac{L_{true,N} - \hat{L}_N}{L_{true,N}} \times 100$, $f(l_N)$ 表示预测时刻 RUL 的概率分布. 基于上述定义, 相应的结果如图 7 所示.




图7 不同预测步长下 RUL 预测结果的评估指标比较

不难看出,随着预测步长的增加,MAE 将会随之增加,而 SOA 会呈现降低趋势. 而对于 MSE,在 600 个循环与 650 个循环时与预测步长保持正相关的态势,但在 700 个循环与 750 个循环时这种增幅并非如此明显. 根据上述结果,可得出如下结论:(1)由于锂电池的运行环境是复杂多变的,在较大步长下掌握锂电池的健康状态是十分困难的,因而预测步长对预测效果发挥着关键作用,较小的预测步长会获得更加准确的 RUL 预测精度;(2)在面临工程中的突发失效时,较小的预测步长可能会来不及安排维修活动,将会造成意外停机与工程事故,考虑到安全性因素,预测步长并非是越小越好的. 综合结论分析,合适的预测步长对于刻画性能退化趋势与降低停机风险是至关重要的.

6 结论

针对工程中常见的零寿命标签问题,提出一种基于 B-Bi-LSTM 模型的 RUL 预测方法,重点解决了现有以退化信息为标签的预测模型难以刻画 RUL 预测不确定性问题,并且创新性地深度学习框架下区分了首达与非首达两类情形.

考虑到本文中首达意义下的 RUL 分布是近似解,预测结果存在一定误差,在后续研究中将重点考虑如何得到首达意义下的 RUL 分布精确解.

参考文献

[1] PAN Y N, CHENG D L, WEI T T, et al. Rolling bearing performance degradation assessment based on deep belief

network and improved support vector data description[J]. Mechanical Systems and Signal Processing, 2022, 181: 109458.

- [2] PEI H, SI X S, HU C H, et al. An adaptive prognostics method for fusing CDBN and diffusion process: application to bearing data[J]. Neurocomputing, 2021, 421: 303-315.
- [3] SI X S, REN Z Q, HU X X, et al. A novel degradation modeling and prognostic framework for closed-loop systems with degrading actuator[J]. IEEE Transactions on Industrial Electronics, 2020, 67(11): 9635-9647.
- [4] LEI Y G, LI N P, GUO L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal Processing, 2018, 104: 799-834.
- [5] 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, 55(8): 1-13.
- PEI H, HU C H, SI X S, et al. Review of machine learning based remaining useful life prediction methods for equipment[J]. Journal of Mechanical Engineering, 2019, 55(8): 1-13. (in Chinese)
- [6] 李天梅, 司小胜, 张建勋. 多源传感监测线性退化设备数模联动的剩余寿命预测方法[J/OL]. 航空学报, 2022: 1-19[2022-10-20]. <https://kns.cnki.net/kcms/detail/11.1929.V.20220608.1202.006.ht-ml>.
- LI T M, SI X S, ZHANG J X. Data-model interactive remaining useful life prediction method for multi-sensor

- monitored linear stochastic degrading devices[J/OL]. *Acta Aeronautica et Astronautica Sinica*, 2022: 1-19 [2022-10-20]. <https://kns.cnki.net/kcms/detail/11.1929.V.20220608.1202.006.html>. (in Chinese)
- [7] 孙国玺, 张清华, 文成林, 等. 基于随机退化数据建模的设备剩余寿命自适应预测方法[J]. *电子学报*, 2015, 43(6): 1119-1126.
SUN G X, ZHANG Q H, WEN C L, et al. A stochastic degradation modeling based adaptive prognostic approach for equipment[J]. *Acta Electronica Sinica*, 2015, 43(6): 1119-1126. (in Chinese)
- [8] 张浩, 胡昌华, 杜党波, 等. 多状态影响下基于Bi-LSTM网络的锂电池剩余寿命预测方法[J]. *电子学报*, 2022, 50(3): 619-624.
ZHANG H, HU C H, DU D B, et al. Remaining useful life prediction method of lithium-ion battery based on Bi-LSTM network under multi-state influence[J]. *Acta Electronica Sinica*, 2022, 50(3): 619-624. (in Chinese)
- [9] LIAO L X, JIN W J, PAVEL R. Enhanced restricted boltzmann machine with prognosability regularization for prognostics and health assessment[J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(11): 7076-7083.
- [10] YU W N, KIM II Y, MECHEFSKE C. Remaining useful life estimation using a bidirectional recurrent neural network based autoencoder scheme[J]. *Mechanical Systems and Signal Processing*, 2019, 129: 764-780.
- [11] 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*, 2018, 48(1): 11-20.
- [12] DEUTSCH J, HE M, HE D. Remaining useful life prediction of hybrid ceramic bearings using an integrated deep learning and particle filter approach[J]. *Applied Sciences*, 2017, 7(7): 649.
- [13] HUANG C G, HUANG H Z, LI Y F. A bidirectional LSTM prognostics method under multiple operational conditions[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(11): 8792-8802.
- [14] SONG Y, SHI G, CHEN L Y, et al. Remaining useful life prediction of turbofan engine using hybrid model based on autoencoder and bidirectional long short-term memory [J]. *Journal of Shanghai Jiaotong University (Science)*, 2018, 23(1): 85-94.
- [15] PAISLEY J, BLEI D M, JORDAN M I. Variational Bayesian inference with stochastic search[C]//Proceedings of the 29th International Conference on International Conference on Machine Learning. New York: ACM, 2012: 1363-1370.
- [16] GAL Y, GHAHRAMANI Z. Dropout as a Bayesian approximation: Representing model uncertainty in deep learning[C]//Proceedings of the 33rd International Conference on International Conference on Machine Learning - Volume 48. New York: ACM, 2016: 1050-1059.
- [17] PENG W W, YE Z S, CHEN N. Bayesian deep-learning-based health prognostics toward prognostics uncertainty [J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(3): 2283-2293.
- [18] WANG B, LEI Y G, YAN T, et al. Recurrent convolutional neural network: A new framework for remaining useful life prediction of machinery[J]. *Neurocomputing*, 2020, 379: 117-129.
- [19] LI G Y, YANG L, LEE C G, et al. A Bayesian deep learning RUL framework integrating epistemic and aleatoric uncertainties[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(9): 8829-8841.
- [20] LIN Y H, LI G H. A Bayesian deep learning framework for RUL prediction incorporating uncertainty quantification and calibration[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(10): 7274-7284.
- [21] 陈云翔, 王泽洲, 蔡忠义, 等. 基于EM-EKF与隐含比例退化模型的机载电子设备剩余寿命自适应预测[J]. *电子学报*, 2021, 49(3): 500-509.
CHEN Y X, WANG Z Z, CAI Z Y, et al. Adaptive prediction of remaining useful lifetime for the airborne electronic equipment based on the EM-EKF algorithm and hidden degradation model with the proportion relationship [J]. *Acta Electronica Sinica*, 2021, 49(3): 500-509. (in Chinese)
- [22] ELSHEIKH A, YACOUT S, OUALI M S. Bidirectional handshaking LSTM for remaining useful life prediction [J]. *Neurocomputing*, 2019, 323: 148-156.
- [23] ZHENG S, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation[C]//2017 IEEE International Conference on Prognostics and Health Management (ICPHM). Piscataway: IEEE, 2017: 88-95.
- [24] SONG S L, COIT D W, FENG Q M. Reliability analysis of multiple-component series systems subject to hard and soft failures with dependent shock effects[J]. *IIE Transactions*, 2016, 48(8): 720-735.
- [25] 张正新, 胡昌华, 司小胜, 等. 双时间尺度下的设备随机退化建模与剩余寿命预测方法[J]. *自动化学报*, 2017,

43(10): 1789-1798.

ZHANG Z X, HU C H, SI X S, et al. Degradation modeling and remaining useful life prediction with bivariate time scale[J]. Acta Automatica Sinica, 2017, 43(10): 1789-1798. (in Chinese)

[26] PECHT M. CALCE Battery Group[DS/OL]. <https://web.calce.umd.edu/batteries/data.htm>.

[27] YU Y, HU C H, SI X S, et al. Averaged Bi-LSTM networks for RUL prognostics with non-life-cycle labeled dataset[J]. Neurocomputing, 2020, 402: 134-147.



董青 男, 1996 年生于河北邯郸. 现为火箭军工程大学博士研究生. 主要研究方向为装备的剩余寿命预测与维修决策.

E-mail: 18756528162@163.com

作者简介



裴洪 男, 1992 年生于安徽霍邱. 现为火箭军工程大学讲师. 主要研究方向为装备的剩余寿命预测与维修决策.

E-mail: ph2010hph@sina.com



司小胜 男, 1984 年生于甘肃通渭. 现为火箭军工程大学教授、博士生导师. 主要研究方向为复杂系统寿命预测与维修决策.

E-mail: sixiaosheng@126.com



胡昌华 男, 1966 年生于湖北罗田. 现为火箭军工程大学教授、博士生导师. 主要研究方向为复杂系统故障诊断、寿命预测与容错控制.

E-mail: hch66603@163.com



郑建飞 男, 1980 年生于河北霸州. 现为火箭军工程大学副教授、硕士生导师. 主要研究方向为复杂系统寿命预测与维修决策.

E-mail: zjf302@126.com



张建勋 男, 1988 年生于四川南充. 现为火箭军工程大学讲师, 硕士生导师. 主要研究方向为预测与健康管理、退化过程建模、剩余寿命估计.

E-mail: zhang200735@163.com