

多状态影响下基于Bi-LSTM网络的锂电池剩余寿命预测方法

张 浩,胡昌华,杜党波,裴 洪,张建勋

(火箭军工程大学导弹工程学院,陕西西安 710025)

摘 要: 现有基于深度学习的锂电池剩余寿命(Remaining Useful Life, RUL)预测方法中,锂电池多个内部状态所蕴含的寿命信息未得到充分考虑. 鉴于此,提出了一种融合电池容量、阻抗与温度三个内部状态的RUL预测模型. 首先,引入双向长短时记忆(Bi-directional Long Short-Term Memory, Bi-LSTM)网络学习三种状态数据的时间相关性. 其次,利用dropout技术与Bayesian变分推断技术间的等价性实现了RUL预测结果的不确定性量化,得到了预测结果的95%置信区间与概率密度分布(Probability Density Function, PDF),并分析了不同dropout率对预测不确定性的影响. 最后,通过四种不同的深度学习模型框架与两种内部状态输入方案的对比实验,验证了本文方法的有效性.

关键词: 深度学习; 剩余寿命预测; Bi-LSTM网络; Bayesian变分推断技术; dropout技术; 不确定性量化

中图分类号: TP206+.3

文献标识码: A

文章编号: 0372-2112(2022)03-0619-06

电子学报URL: <http://www.ejournal.org.cn>

DOI:10.12263/DZXB.20210207

Remaining Useful Life Prediction Method of Lithium-Ion Battery Based on Bi-LSTM Network Under Multi-State Influence

ZHANG Hao, HU Chang-hua, DU Dang-bo, PEI Hong, ZHANG Jian-xun

(College of Missile Engineering, Rocket Force University of Engineering, Xi'an, Shaanxi 710025, China)

Abstract: The life information contained in multiple internal states of lithium-ion battery is not fully considered in the existing RUL(Remaining Useful Life) prediction methods of lithium-ion battery based on deep learning. In view of this, a RUL prediction model that integrates the three internal states include battery capacity, impedance and temperature is proposed. The Bi-LSTM(Bi-directional Long Short-Term Memory) network is introduced to learn the correlation about time of the data of the three states firstly. Secondly, the equivalence between dropout technology and Bayesian variational inference technology is used to quantify the uncertainty of the RUL prediction results. The 95% confidence interval and PDF(Probability Distribution Function) of the RUL prediction results are obtained, and the effect on the prediction uncertainty of different dropout rates is analyzed. Finally, the effectiveness of this method is verified through the comparative experiments of four different deep learning model and two input schemes of internal state.

Key words: deep learning; remaining useful life prediction; bi-directional long short-term memory network; Bayesian variational inference technology; dropout technology; quantification of uncertainty

1 引言

锂电池以其充电速率快与使用寿命长等优越性能被广泛应用于新能源汽车、通信设备与航空航天电子设备领域^[1]. 然而,随着锂电池循环使用次数的累积,电池性能不可避免地发生衰退,最终导致系统无法正常工作甚至可能造成安全事故^[2]. 因此,高效准确的预

测锂电池的剩余寿命(Remaining Useful Life, RUL)具有重要的实际意义^[3].

通过预测锂电池运行过程中容量、阻抗等状态的动态变化可实现电池RUL的预测^[4],现有锂电池的RUL预测方法主要包括基于模型的方法与数据驱动方法两类^[5]. 数据驱动方法无需根据系统内部复杂的退

化机理而建立特定的预测模型,直接利用锂电池循环充放电过程中的监测数据来拟合电池性能的退化规律,进而实现锂电池的RUL预测^[6,7],相对基于模型的方法来说更具有普适性。

深度学习作为数据驱动方法的分支,以其强大的数据处理能力被广泛应用于锂电池RUL预测领域.Zhao等^[8]结合深度置信网络与支持向量机(Support Vector Machine, SVM)实现了锂电池容量退化的预测,并通过容量外推得到了电池RUL.文献[9]则进一步考虑锂电池循环使用过程中的放电电流与环境温度对容量退化的影响,建立考虑外部状态影响下的锂电池容量与RUL预测模型.Zhou等^[10]利用人工神经网络与SVM实现了电池温度至RUL的预测.文献[11]同样以电池温度为基础,但建立的模型为多通道神经网络容量预测模型,并综合考虑充放电端电压与电流在电池性能退化中的作用.而Xu等^[12]在文献[10]的基础上将电压纳入堆叠去噪自动编码器直接预测锂电池的RUL.然而上述文献仅以一种内部状态(即容量或电池温度)搭建锂电池的RUL预测模型,忽略了电池运行过程中各内部状态的相互作用,因此难以充分利用各状态所包含的寿命信息,一定程度上影响着预测结果的准确性.此外,在利用深度学习实现锂电池的RUL预测时,多数文献未对预测结果进行不确定性量化或量化的计算过于复杂。

综上,针对现有RUL预测方法中的问题与不足,本文充分考虑锂电池循环使用过程中的容量、阻抗与温度信息,以三种状态数据为Bi-LSTM网络的输入,其循环寿命为网络输出搭建锂电池的RUL预测模型.同时,借鉴文献[13]中Bayesian变分推断技术与dropout技术间的等价性,实现RUL预测结果的不确定性量化;最后,通过Severson教授课题组的锂电池数据集对比验证了该模型的有效性。

2 基于Bi-LSTM的锂电池RUL预测模型

2.1 Bi-LSTM模型

LSTM网络主要包含遗忘门、输入门与输出门三部分,分别表示为 f_t 、 i_t 、 o_t .网络传递的途径如式(1)所示。

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

式中, x_t 表示 t 时刻神经元的输入, h_t 表示 t 时刻的输出, c_t 表示当前神经元状态, W, U 为权重矩阵, b 为偏置, σ 为Sigmoid函数, \odot 表示按元素乘积。

但LSTM仅学习了过去状态对当前状态的影响,忽略了未来状态的作用,没有充分利用时间序列的前后依赖性关系,对数据的学习能力有限.而Bi-LSTM网络能同时学习过去与未来状态对当前状态的作用,极大提高了模型对具有前后依赖关系的长序数据的学习能力.Bi-LSTM网络通过前向层与后向层可独立地对时序数据进行处理,并将两层处理结果同时前馈到输出层,能够充分利用过去与未来时刻数据所蕴含的寿命信息.鉴于此,本文采用Bi-LSTM网络进行建模,完整的Bi-LSTM网络前向与后向过程的输出结果为式(2)所示。

$$H_t = \vec{h}_t + \overleftarrow{h}_t \quad (2)$$

式中, \vec{h}_t 为最后一个前向层的输出, \overleftarrow{h}_t 为最后一个后向层的输出, H_t 为网络最终输出。

2.2 基于Bi-LSTM网络的锂电池RUL预测

本文的预测结构如图1所示,首先采用独立的Bi-LSTM-1网络提取三个内部状态的时序特征信息,再利用特征融合技术将三部分特征信息进行拼接,最后将拼接的特征输入到Bi-LSTM-2网络以实现考虑特征相关性的同时提取具有时间关系的深度特征。

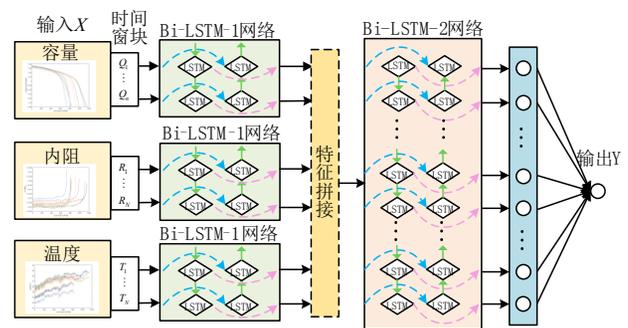


图1 基于Bi-LSTM网络的锂电池RUL预测模型

所提模型通过堆叠多个Bi-LSTM网络实现模型对数据间的相关性与时序依赖关系的学习,并通过一个全连接层与回归层得到电池的RUL.此外,本文选用均方根误差(Root Mean Square Error, RMSE)与平均绝对误差(Mean Absolute Error, MAE)两个指标对模型的性能进行评估,其公式如下。

$$\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \\ \text{MAE} &= \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \end{aligned} \quad (3)$$

其中, m 为数据总数, y_i 表示锂电池第 i 个时刻真实的RUL, \hat{y}_i 表示模型在第 i 个时刻的RUL预测值。

2.3 预测结果不确定性量化

尽管基于Bi-LSTM网络的RUL预测模型对时序数

据具有强大的学习能力,能取得更高的预测精度,但该模型的预测结果仅为点估计而非区间估计,无法反映预测结果的不确定性.为描述预测结果的不确定性,在模型中引入 Bayesian 神经网络^[14],将 Bi-LSTM 网络的参数视为服从某种分布的随机变量. X 表示训练数据集, Y 表示相应的真实 RUL 标签.

令随机变量 $\theta = \{W, b\}$ 表示模型的参数,其中 W 与 b 分别表示网络的权重与偏置向量. $p(\theta)$ 表示参数 θ 的先验分布, $q(\theta)$ 表示 $p(\theta)$ 的近似变分分布,通过最小化两个分布间的 Kullback-Leibler(KL)散度可得到最优的近似分布.考虑到神经元数目较多时,求 KL 散度较为复杂,利用 dropout 技术与 Bayesian 变分推断间的等价性,在 L^2 正则化条件下,将目标函数优化为:

$$L_{\text{dropout}} = \frac{1}{p} \sum_{k \in S} E(Y, \bar{Y}) + \sum_{h=1}^H \left[\lambda \|W\|^2 + \lambda \|b\|^2 \right] \quad (4)$$

式(4)中, S 为训练样本的子集, p 为子集的数目, H 表示模型参数的总数, \bar{Y} 表示利用 dropout 技术所获得的模型输出, λ 表示正则化技术的衰减系数.

通常采用 Adam 优化方法对目标函数式(4)进行优化,当获得模型参数后验分布的最优近似分布后,对新获得的输入样本 X^* ,模型 RUL 预测结果的分布为:

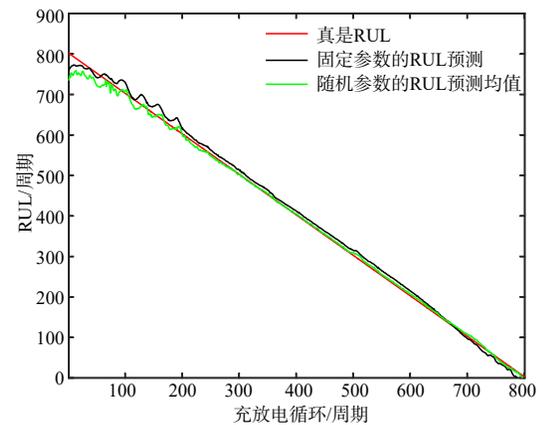
$$\begin{aligned} p(Y_k^* | X_k^*, X, Y) &\approx \int p(Y_k^* | X_k^*, \theta) q^*(\theta) d\theta \\ &\approx \frac{1}{T} \sum_{t=1}^T p(Y_k^* | X_k^*, \hat{\theta}_t) \end{aligned} \quad (5)$$

式中, $\hat{\theta}_t$ 为 $q^*(\theta)$ 的特定采样值, T 为循环采样的次数.

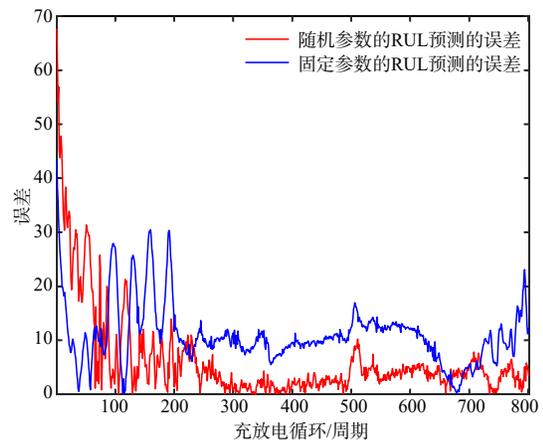
3 实例验证与结果分析

本文采用美国 Severson 教授课题组的商用磷酸铁锂电池“2017-05-12”批次数据集^[15]对模型的性能进行验证.数据集中部分电池由于仪器测量误差等原因导致所获取的状态数据存在较大波动.为建立预测性能更好的 RUL 预测模型,本文在实验中剔除状态异常的电池数据,保留变化趋势符合实际的电池,以此数据搭建锂电池的 RUL 预测模型.以剩余 10 个电池中前 9 个锂电池的容量、阻抗与温度为模型输入,锂电池的剩余使用周期数为输出对模型进行训练.首先利用 Min-Max 方法对电池容量、阻抗与温度数据进行归一化处理,采用滑动时间窗技术生成固定长度的训练样本,其中滑动时间窗长度设为 10,步长设为 1,将经过上述预处理操作后的电池数据输入至模型中进行训练.

设置不同网络结构时预测效果存在差异,为选择合适模型进行预测,需对不同超参数下的模型性能进行对比.利用滑动时间窗技术处理原始数据后得到 9216 个数据段,每个数据段具有 10 个充放电循环的数据.通过对比发现将模型的学习率设为 0.01, Bi-LSTM-1 设为为



(a) RUL 预测结果对比图



(b) RUL 预测误差对比图

图 2 固定参数与随机参数模型的 RUL 预测结果及误差

层具有 64 个神经元的双隐藏层, Bi-LSTM-2 则为具有 64 个神经元的单隐藏层,最后的全连接层包含 100 个神经元,训练 epoch 为 10000,每个 epoch 包含 90 个随机的数据段,此时模型的 RMSE 最低, RUL 预测精度最高.

为了验证本文基于等价 Bayesian 深度学习算法与 Bi-LSTM 网络的锂电池 RUL 预测方法的有效性,我们将固定 Bi-LSTM 网络参数模型在第 10 号电池的预测效果同本文方法进行对比,其中开始预测时的真实 RUL 为 802 个循环周期.当锂电池已运行某个周期后,分别采用固定模型参数法与随机参数法预测该电池还能有效工作的循环周期.由于本文模型参数的随机性与预测结果的唯一性,通过 1000 次循环预测可得到 1000 组锂电池的 RUL 预测值,每组包含 802 个预测循环.将模型权重与偏置分别视为服从高斯混合分布与高斯分布时,最终 RUL 预测结果亦服从高斯分布^[14],根据 802×1000 个 RUL 预测结果可得到 802 个点处的预测结果的均值 μ 与标准差 σ ,利用式(6)即可得到预测结果的 95% 置信区间,不同 dropout 率下 RUL 预测结果的 95% 置信区间如图 3 所示.

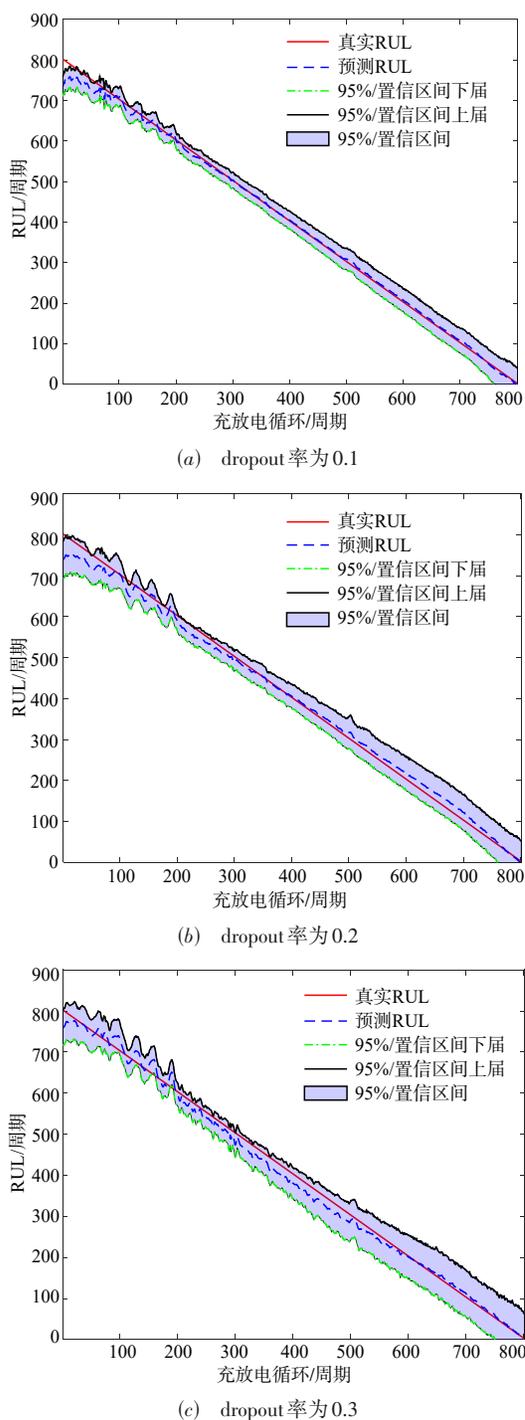


图3 不同 dropout 率下 RUL 预测结果的 95% 置信区间

$$P(\mu - 1.96 \frac{\sigma}{\sqrt{n}} \leq M \leq \mu + 1.96 \frac{\sigma}{\sqrt{n}}) \approx 0.95 \quad (6)$$

式中, n 为样本数, M 为样本均值.

从图 2(a) 中可以直观看出, 随机参数模型的预测均值与真实 RUL 值更接近, 拟合效果更好; 图 2(b) 展示了 dropout 率为 0.1 时两种模型的预测误差对比情况. 随机参数模型与固定参数模型的 RMSE 均值分别为

10.497 与 12.383, 二者的 MAE 分别为 6.262 与 11.022, 因此具有参数随机性的模型预测精度更高. 此外, 利用 dropout 技术等价地实现 RUL 预测结果的不确定性量化时, 不同 dropout 率对 RUL 预测结果的不确定性影响不同. 为探究不同 dropout 率下 RUL 预测的差异性表现, 此处以 dropout 率分别等于 0.1、0.2、0.3 时为例进行展示.

从图 3 可以直观发现, 随着 dropout 率的增大, RUL 预测结果 95% 置信区间的宽度逐渐增大, 与预测结果的不确定性呈正相关, 即 dropout 率的增大将提高模型训练过程中随机丢失信息的比例, 因而增加了预测结果的不确定性. 此外, 不确定性的增加将使初始阶段的置信区间宽度增加, 从而使预测区间更容易包含真实的 RUL, 即一定程度上提高了预测初始时刻 RUL 的准确性. 表 1 为第 10 个电池运行了 600 个、700 个与 800 个循环后 RUL 预测结果 95% 置信区间的宽度, 可以明显发现, 随着 dropout 率的增大, 置信区间的宽度随之增大, 进一步验证了 RUL 预测结果的不确定性与 dropout 率间的正相关关系.

表 1 不同 dropout 率下置信区间宽度

dropout 率	预测周期		
	第 600 个循环	第 700 个循环	第 800 个循环
0.1	39.57	40.02	39.83
0.2	49.74	49.86	50.05
0.3	51.12	51.05	50.53

基于 1000 组 RUL 预测值在 MATLAB 中利用核密度估计函数可得到预测结果的概率密度分布 (Probability Density Function, PDF), 图 4 为不同 dropout 率下第 600 个循环 RUL 预测结果的 PDF.

如图 4 所示, 当 dropout 率增大时, 第 600 个循环 RUL 预测结果 PDF 的高度随之减小, 宽度相反随之增

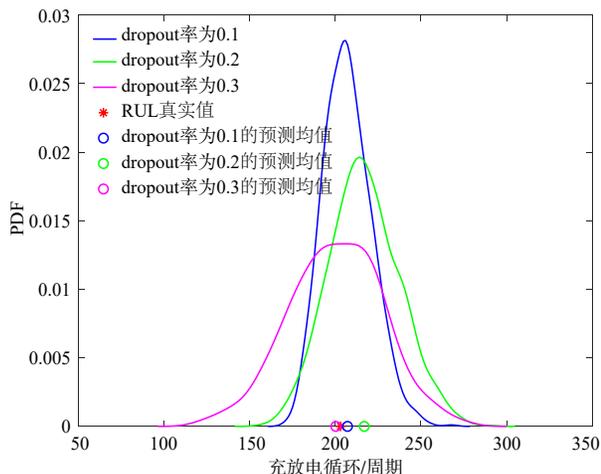


图 4 不同 dropout 率下第 600 个循环 RUL 的 PDF

大,即随着 dropout 率的增加,RUL 预测结果的不确定性增加.RUL 预测结果的不确定性直接影响着设备健康管理活动的合理性与科学性,较小不确定性有助于精准制定设备的维修策略.但过度追求较小不确定性可能会造成预测结果无法较好反映实际工程中测量误差与个体差异性等各类不确定因素的问题.为保证 RUL 预测精度的同时考虑 RUL 预测结果的不确定性,本文从集合 $\{0, 0.05, 0.1, 0.2, 0.3\}$ 中选择 dropout 率进行分析,不同 dropout 率下 RUL 预测结果的 RMSE 如表 2 所示.

表 2 不同 dropout 率下 RUL 预测结果的 RMSE

Dropout 率	0	0.05	0.1	0.2	0.3
RMSE	12.383	12.049	10.497	12.564	12.891

从表 2 中可以看出 dropout 率设为 0.1 时,RUL 预测结果的 RMSE 最小.此外,图 3 进一步验证了 dropout 率为 0.1 的合理性与优越性,能够充分反映实际中各类不确定因素的影响.

为验证本文考虑电池阻抗与温度后建立的 Bi-LSTM 模型的优越性,引入七种方法与本文方法进行对比分析,其中主要包含 GRU、Bi-GRU、LSTM、Bi-LSTM 四种针对时序数据具有强大学习能力的网络结构,再分别考虑每种网络是否融入电池阻抗、温度实现锂电池的 RUL 预测,共八种 RUL 预测方法分别记为方法 1~8,方法 1~4 为四种网络仅根据电池退化容量对锂电池 RUL 进行预测,方法 5~8 为四种网络考虑电池容量、阻抗与温度后进行 RUL 预测,需要说明的是方法 8 即为本文方法.此外,方法 1~7 同样采用 dropout 深度学习技术对 RUL 预测结果的不确定性进行量化,并选择 RMSE、MAE 与循环 1000 次预测时间三种指标对 RUL 预测结果进行评估,对比结果如表 3 所示.

表 3 八种方法的 RUL 预测结果性能指标对比

预测方法	RMSE	MAE	循环 1000 次 预测时间(s)
方法 1	32.930	33.548	7.036
方法 2	20.876	21.597	7.195
方法 3	31.511	26.562	7.303
方法 4	20.251	19.570	8.412
方法 5	16.897	14.579	12.408
方法 6	13.737	11.040	13.048
方法 7	13.096	10.328	14.294
本文(方法 8)	10.497	6.262	14.978

从表 3 的对比结果可以发现,在所有模型中,本文方法即考虑电池退化过程中的容量、阻抗与温度三种状态对电池 RUL 的影响,并基于等价 Bayesian 变分推断技术与 Bi-LSTM 网络进行建模时,RUL 预测的 RMSE

与 MAE 均为最小.但本文方法的预测时间并非最短,主要由网络结构复杂程度与输入变量的个数两方面因素造成,结构越复杂且考虑内部状态的因素越多,模型预测时间越长.此外,相对于方法 1、3、5、7,方法 2、4、6、8 在预测时对数据两个方向上的时间相关性进行了学习,因此其 RMSE 与 MAE 更小.方法 1~4 的 RMSE 与 MAE 均大于对应的方法 5~8,进一步论证在进行锂电池的 RUL 预测时,融入电池阻抗、温度等多种状态后得到的 RUL 预测结果精度更高.综上,本文方法预测性能更优,且能考虑各种随机因素的影响,对 RUL 预测的不确定性进行度量,并提供 RUL 预测结果的 PDF,为设备开展维修活动提供理论支撑.

4 结论

高效准确地预测锂电池的 RUL 在电池的健康管理系统中发挥着越来越重要的作用.本文提出了一种融合多个内部状态的锂电池 RUL 预测方法,以电池容量、阻抗与温度为核心,直接实现三种电池状态至 RUL 的预测,最后基于 Bayesian 变分理论与 dropout 技术间的等价性对 RUL 预测结果的不确定性进行量化.并将本文的 RUL 预测结果同四种引入深度学习模型的预测结果进行对比,验证了本文方法的有效性与优越性.

参考文献

- [1] TANG X, ZOU C, WIK T, et al. Run-to-run control for active balancing of lithium iron phosphate battery packs[J]. IEEE Transactions on Power Electronics, 2019, 35(2): 1499-1512.
- [2] SI X, LI T, ZHANG Q, et al. Prognostics for linear stochastic degrading systems with survival measurements[J]. IEEE Transactions on Industrial Electronics, 2019, 67(4): 3202-3215.
- [3] 刘月峰, 赵光权, 彭喜元. 多核相关向量机优化模型的锂电池剩余寿命预测方法[J]. 电子学报, 2019, 47(6): 1285-1292.
LIU Yue-feng, ZHAO Guang-quan, Peng Xi-yuan. A lithium-ion battery remaining using life prediction method based on multi-kernel relevance vector machine optimized model[J]. Acta Electronica Sinica, 2019, 47(6): 1285-1292. (in Chinese)
- [4] DONG G, CHEN Z, WEI J, et al. Battery health prognosis using Brownian motion modeling and particle filtering[J]. IEEE Transactions on Industrial Electronics, 2018, 65(11): 8646-8655.
- [5] LIU C, WANG Y, CHEN Z. Degradation model and cycle life prediction for lithium-ion battery used in hybrid energy

storage system[J]. Energy, 2019, 166: 796-806.

- [6] 郑建飞, 胡昌华, 司小胜, 等. 考虑不完全维护影响的随机退化设备剩余寿命预测[J]. 电子学报, 2017, 45(7): 1740-1749.

ZHENG Jian-fei, HU Chang-hua, SI Xiao-sheng, et al. Remaining useful life prognostic for the stochastic degradation device subject to imperfect maintenance[J]. Acta Electronica Sinica, 2017, 45(7): 1740-1749. (in Chinese)

- [7] 周绍华, 胡昌华, 司小胜, 等. 融合非线性加速退化模型与失效率模型的产品寿命预测方法[J]. 电子学报, 2017, 45(5): 1084-1089.

ZHOU Shao-hua, HU Chang-hua, SI Xiao-sheng, et al. Life prediction approach by integrating nonlinear accelerated degradation model and hazard rate model[J]. Acta Electronica Sinica, 2017, 45(5): 1084-1089. (in Chinese)

- [8] ZHAO G, ZHANG G, LIU Y, et al. Lithium-ion battery remaining useful life prediction with deep belief network and relevance vector machine[C]//2017 IEEE International Conference on Prognostics and Health Management (ICPHM). Harbin, China: IEEE, 2017: 7-13.

- [9] ZHANG Y, XIONG R, HE H, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. IEEE Transactions on Vehicular Technology, 2018, 67(7): 5695-5705.

- [10] ZHOU X, HSIEH S J, PENG B, et al. Cycle life estimation of lithium-ion polymer batteries using artificial neural network and support vector machine with time-resolved thermography[J]. Microelectronics Reliability, 2017, 79: 48-58.

- [11] PARK K, CHOI Y, CHOI W J, et al. LSTM-based battery remaining useful life prediction with multi-channel charging profiles[J]. IEEE Access, 2020, 8: 20786-20798.

- [12] XU F, YANG F, FEI Z, et al. Life prediction of lithium-ion batteries based on stacked denoising autoencoders[J]. Reliability Engineering and System Safety, 2021, 208: 107396.

- [13] WANG B, LEI Y, YAN T, et al. Recurrent convolutional neural network: A new framework for remaining useful life prediction of machinery[J]. Neurocomputing, 2020, 379: 117-129.

- [14] PENG W, YE Z, CHEN N. Bayesian deep-learning-based health prognostics toward prognostics uncertainty[J]. IEEE Transactions on Industrial Electronics, 2020, 67(3): 2283-2293.

- [15] SEVERSON K A, ATTIA P M, JIN N, et al. Data-driven prediction of battery cycle life before capacity degradation

[J]. Nature Energy, 2019, 4(5): 383-391.

作者简介



张浩 男, 1996年生于陕西安康. 现为火箭军工程大学导弹工程学院硕士研究生. 主要研究方向为基于深度学习的设备剩余寿命估计与故障预测.

E-mail: zhzhshjj@163.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



杜党波 男, 1989年生于陕西西安. 现为火箭军工程大学讲师. 主要研究方向为预测与健康管理、剩余寿命估计.

E-mail: luyq@mail.tsinghua.edu.cn



裴洪 男, 1992年生于安徽六安. 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: ddb_effort@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. 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