DOI: 10. 13382/j. jemi. B2003108

基于 CEEMDAN 和 SVR 的锂离子电池 剩余使用寿命预测*

杨彦茹 温 杰 史元浩 张泽慧 刘文海 (中北大学 电气与控制工程学院 太原 030051)

摘 要:锂离子电池剩余使用寿命(RUL)的估算是锂离子电池健康管理的关键,准确可靠地预测锂离子电池的剩余使用寿命对 系统的安全正常运行至关重要。提出了一种结合完备集合经验模态分解(CEEMDAN)和支持向量回归(SVR)的锂离子电池剩 余使用寿命预测方法。首先,在放电过程中提取了一个可测量的健康因子,并使用 Pearson 和 Spearman 法分析健康因子与容量 之间的相关性,然后利用 CEEMDAN 将健康因子进行分解,获得一系列相对平稳的分量,最后采用 CEEMDAN 分解后的健康因 子作为 SVR 预测模型输入,容量作为输出,实现锂离子电池 RUL 预测。利用 NASA PCoE 提供的锂离子电池退化数据集进行试 验,与标准 SVR 模型相比,实验结果表明利用该方法能够有效验证所提出的 RUL 预测模型的有效性,并且使预测误差控制在 2%以下。

Remaining useful life prediction for lithium-ion battery based on CEEMDAN and SVR

Yang Yanru Wen Jie Shi Yuanhao Zhang Zehui Liu Wenhai

(School of electrical and control engineering, North University of China, Taiyuan 030051, China)

Abstract: Estimation of lithium-ion battery remaining useful life (RUL) is the key to lithium-ion battery health. Achieving accurate and reliable remaining useful life prediction of lithium-ion batteries is very vital for the normal operation of the battery system. Proposes a lithium-ion battery RUL prediction method based on the combination of complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and support vector machine-regression (SVR). First, a measurable health factor is extracted during the discharge process, and the correlation between health factor and capacity is analyzed by Pearson and Spearman methods. Then, the health factor is decomposed by CEEMDAN to obtain a series of the relatively stable components. Finally, the health factor decomposed by CEEMDAN is used as the input of SVR prediction model, and the capacity is used as the output, so as to realize lithium-ion RUL prediction. The lithium-ion battery data published by NASA PcoE is used to carry out simulation experiments, and compare it with the standard SVR model, the experimental results show that the proposed method can effectively verify the effectiveness of the proposed RUL prediction model, and the proposed method can effectively verify the effectiveness of the proposed RUL prediction model, and the prediction error is controlled below 2%.

Keywords: lithium-ion battery; remaining useful life; support vector regression; complete ensemble empirical mode decomposition with adaptive noise

0 引 言

锂离子^[1]电池具有能量密度高、使用寿命长、自放电

率低等优点,已被广泛应用于交通^[2-3]、通信、航空航天^[4] 等领域。然而锂离子电池在使用过程中内部会发生复杂 的物理和化学变化,其性能会退化甚至失效,存在引发重 大安全事故的危险,因此研究锂离子电池剩余使用寿命

收稿日期:2020-04-29 Received Date: 2020-04-29

^{*}基金项目:国家自然科学基金(61533013)、山西省重点研发计划(201703D111011)、山西省自然科学基金(201801D121159)、山西省青年自然 科学基金(201801D221208)、山西省高等学校科技创新项目(2019L0583)、山西省研究生教育创新项目(2020SY408,2020SY405)资助

(remaining useful life,RUL)具有重要的实际意义^[5]。为 了解决锂离子电池剩余使用寿命预测的准确度和可靠性 问题,目前主要采用基于模型^[6-7]、基于数据驱动^[8]以及 模型与数据驱动相融合 3 种方法。

基于模型的方法主要是通过分析锂离子电池的物 理和化学原理,建立数学和物理模型来描述锂离子电 池性能退化的过程,如建立等效电路模型^[9]、电化学模 型^[10]、布朗运动模型和粒子滤波^[11]等退化模型实现在 线短期健康状态(state of health, SOH)估计和长期 RUL 预测。虽然基于模型的方法也取得了良好的效果,但 是由于电池内部的变化比较复杂,这种方法容易受到 噪声和环境干扰的影响,难以实现对锂离子电池的精 确建模。与其相比,数据驱动方法^[12-13]更方便,它仅依 赖于对锂离子电池历史数据的挖掘。现在越来越多的 学者使用数据驱动的方法来预测锂离子电池的 RUL。 如差分整合移动平均自回归(autoregressive integrated moving average, ARIMA)模型^[14]、支持向量机(SVM)模 型、神经网络模型^[15]等,但是锂离子电池退化过程的容 量回升会影响预测算法的性能,在实际应用中很难进 行有效的预测。

针对以上问题,Dong 等^[16]提出了模型与数据驱动相 融合的方法,使用了基于支持向量机回归与粒子滤波 (support vector regression-particle filter,SVR-PF)的电池 SOH 监控模型,并引入了新的容量参数来实时确定电 池的健康状况。在此基础上,Zhang 等^[17]提出了一种 基于马尔可夫链蒙特卡罗的改进无味粒子滤波方法用 于锂离子电池 RUL 预测。基于模型与数据驱动的方法 虽然有效提高了 RUL 预测的准确度,但目前这类方法 存在一些问题。1)融合方法的参数更复杂,计算量大, 运行时间长;2)预测结果不确定性高,泛化性较差,模 型不稳定。

除此之外,吴祎等^[18]提出了变分模态分解与高斯过 程回归的方法,将锂离子电池容量分解以获取锂离子电 池退化趋势分量和容量再生分量,进而实现锂离子电池 RUL预测。虽然考虑到了容量回升问题,但由于电池容 量需要精密昂贵的专业设备进行测量故难以在线监 测^[19]。为了解决 RUL 在线预测问题,Zhou 等^[20]从锂离 子电池的运行参数中提取了一种新的健康因子(health indicator,HI),并采用 Box-Cox 变换来提高 HI 性能,然 后,利用 Pearson 和 Spearman 相关分析来评估容量与变 换后的 HI 之间的相关性,运用相关向量机(relevance vector machine,RVM)基于提出的 HI 来预测 RUL。Chen 等^[21]从放电电压曲线中提取置换熵作为一种新的 HI,用 于分析电池的劣化,运用一种结合变分模态分解去噪技 术、ARIMA 和灰色模型的 RUL 预测方法。Zhao 等^[22]提 取了两个 HIs,一个是相等充电电压差的时间间隔,另一 个是相等放电电压差的时间间隔,利用特征向量选择和 SVR 相结合的新方法来模拟这两个 HIs 和容量之间的 关系,可以更准确地预测 SOH 和 RUL。即使文 献[19-21]提取到的 HI 与容量相关性很高,但由于未 考虑如何进一步处理容量回升部分,从而导致模型预 测能力受到限制。

本文提出基于 CEEMDAN 和 SVR 的 RUL 预测模型, 在现今的研究基础上进行一定的创新。1)由于多个 HIs 可能会造成信息冗余,导致预测不准确,直接采用单个 HI 不能有效体现容量回升部分,所以本文通过提取与容 量相关性较高的 HI,运用(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)分解 HI 有效捕捉容量回升来预测容量;2)基于统计理论的 SVR 方法可以建立基于结构风险最小化的学习策略,并 解决小样本的非线性函数拟合问题,在回归估计等方面 表现出良好的性能。因此,为了能够对容量回升的波动 部分进行有效预测,建立了多输入单输出的 SVR 模型, 将 CEEMDAN 与 SVR 结合,得出可靠的 RUL 预测结果。

1 CEEMDAN与SVR

1.1 CEEMDAN

CEEMDAN^[23] 是一种时频域分析法,它通过添加自适应性噪声来进一步消除模态效应,拥有很强的自适应性和更好的收敛性,多用于处理非线性和非平稳信号。为了提高锂离子电池 RUL 的预测精度,本文运用CEEMDAN^[24]来处理HI,具体的处理过程如下:将信号分解为 k 个固有模态函数(intrinsic mode function, IMF),每个 *IMF*用*IMF*_k表示。定义操作符 $E_j(\cdot)$ 为通过 EMD 计算获得给定信号的第j 个模态分量,假设s(n)为原始信号,本文将放电电压达到最低点时间作为s(n), CEEMDAN 将满足标准正态分布的高斯白噪声 $\omega(n)$ 加到s(n)之后,执行如下步骤。

1) *IMF*₁ 的计算过程与 EEMD^[25] 相同,信号 *s*(*n*) + $\varepsilon_0 \omega_i(n)$ 被分解 *i* 次,其中参数 ε 控制附加噪声和原始信号之间的信噪比。*IMF*₁ 的计算方法如下:

$$IMF_{1}(n) = \frac{1}{I} \sum_{i=1}^{1} IMF_{i1}(n)$$
(1)

2) 计算残差, k = 1 时残差 $r_1(n)$ 的计算方法如下:

 $r_1(n) = s(n) - IMF_1(n)$ (2)

3)分解 $r_1(n) + \varepsilon_1 E_1(\omega_i(n))(i = 1, 2, \dots, I)$ 至第1 模态量,定义第2个模态分量为:

$$IMF_{2}(n) = \frac{1}{I} \sum_{i=1}^{I} E_{1}(r_{1} + \varepsilon_{1}E_{1}(\omega^{i}(n)))$$
(3)

4) 对于 k =2,…,K,计算第 k 个余量 $r_k(n) = r_{k-1}(n) - IMF_k(n)$ 。

5)分解 $r_k(n) + \varepsilon_k E_k(\omega_i(n))(i = 1, 2, \dots, I)$ 至第1 模态量,定义第k + 1个模态分量为:

$$IMF_{k+1}(n) = \frac{1}{I} \sum_{i}^{i=1} E_{1}(r_{k}(n) + \varepsilon_{k}E_{k}(\omega^{i}(n))) \quad (4)$$

6)将 k +1, 重复步骤 4)~6), 直至余量不适合被分 解, 即余量至多有一个极值。最后原始信号 s(n)可以表 示为 k 个 IMF_k 和一个 r(n), 如下:

$$s(n) = \sum_{k=1}^{k} IMF_{k} + r(n)$$
(5)

1.2 SVR

SVR^[26]可以解决小样本、非线性等问题,在机器学 习中有很强的适用性。

假设给定一个样本集:

$$S = \{\boldsymbol{x}_i, \boldsymbol{y}_i\}_{i=1}^n \tag{6}$$

式中: $x_i(x_i \in X = R^n)$ 是第 i 个输入特征向量; $y_i(y_i \in Y = R)$ 是相应的输出; n 是所有样本的个数。SVR 将数据集通过函数 ψ 转换到高维的特征空间,可以被定义为:

$$f(x) = \boldsymbol{\omega} \cdot \boldsymbol{\psi}(x) + b \tag{7}$$

其中:ω和 b 是待确定的参数。引入松弛变量, SVR 问题 可形式化为:

$$\min_{w,b} \frac{1}{2} \| \omega \|^2 + C \sum_{i}^{n} (\xi_i + \xi_i^*)$$
(8)

s. t.
$$\begin{cases} y_i - \omega \cdot \psi(x) - b \leq \varepsilon + \xi_i \\ \omega \cdot \psi(x) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$
(9)

式中:C为正则化常数; $\varepsilon(\varepsilon > 0)$ 是回归允许的最大误差。引人拉格朗日乘子和核函数可转化为:

$$\max R(\alpha_i^*,\alpha_i) = -\frac{1}{2} \sum_{i,j}^n (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) \varphi(x_i) \cdot$$

$$\varphi(x_j) - \sum_{i}^{n} \alpha_i (y_i + \varepsilon) + \sum_{i}^{n} \alpha_i^* (y_i - \varepsilon)$$
(10)

s. t.
$$\begin{cases} \sum_{i}^{n} (a_{i} - a_{i}^{*}) = 0\\ 0 \leq a_{i}, a_{i}^{*} \leq C, i = 1, 2, \cdots, n \end{cases}$$
 (11)

式中: *a_i*、*a^{*}* 是拉格朗日乘子。在最小化拉格朗日函数 后,得到非线性的 SVR 表达式为:

$$f(x) = \sum_{i}^{n} (\alpha_{i} - \alpha_{i}^{*}) K(x_{i}, x) + b$$
 (12)

式中: *K*(*x_i*,*x*) 是核函数, 径向基函数(RBF) 是 SVR 中 常用的核函数, 其定义为:

$$K_{\rm RBF}(x_i, x) = \exp\left(-\frac{1}{2\sigma^2} \|x_i - x\|^2\right)$$
(13)

其中 σ 为核函数的参数,会影响 SVR 算法的复杂 性。本文通过使用粒子群算法(PSO)^[27]优化与交叉验 证(交叉验证参数 v=5)相结合实现参数(C,g)的寻优, 降低了模型泛化误差,防止模型过拟合。

1.3 基于 CEEMDAN 和 SVR 方法的实现

为了能够充分提取信号所包含的信息和解决传统神 经网络过拟合的问题,根据 CEEMDAN 和 SVR 的特性, 本文提出一种 CEEMDAN 与 SVR 相结合的方法。

图 1 所示为基于 CEEMDAN 和 SVR 模型的容量和 RUL 预测流程,主要为如下 4 个步骤。

1)通过分析锂离子电池的退化过程,提取能够表 征电池容量退化的 HIs 和容量,通过 Pearson 和 Spearman 相关性分析,选取关联度最高的 HI,容量数据 $C,记为 c_1, c_2, ..., c_k, ..., c_i$ 表示第 i 个周期所对应的 容量值, i = 1, 2, 3, ..., t(t 表示总的循坏数, k 表示预 测起始点);

2) 利用 CEEMDAN 对 HI 进行分解, 根据式(5), HI 可以表示为:

$$HI = \sum_{i=1}^{k} IMF_{i} + r(i)$$
(14)

分解后的 HI 可以更准确的捕捉全局退化趋势和回 升部分,提高预测的精度;

3)构造训练集和测试集,将 HI 和容量分为训练集和 测试集,训练集记为 $\{x,y\}$,测试集记为 $\{x_i,y_i\}$,预测 起始位置对应的循环数记为 k + 1。

$$\mathbf{x} = \begin{bmatrix} IMF_{1,1} & IMF_{2,1} & \cdots & IMF_{6,1} & r_1 \\ IMF_{1,2} & IMF_{2,2} & \cdots & IMF_{6,2} & r_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ IMF_{1,k} & IMF_{2,k} & \cdots & IMF_{6,k} & r_k \end{bmatrix}$$
(15)
$$\mathbf{y} = \begin{bmatrix} c_1 & c_2 & \cdots & c_k \end{bmatrix}$$
(16)
$$\mathbf{x}_t = \begin{bmatrix} IMF_{1,k+1} & IMF_{2,k+1} & \cdots & IMF_{6,k+1} & r_{k+1} \\ IMF_{1,k+2} & IMF_{2,k+2} & \cdots & IMF_{6,k+2} & r_{k+2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ IMF_{1,t} & IMF_{2,t} & \cdots & IMF_{6,t} & r_t \end{bmatrix}$$
(17)
$$\mathbf{y}_t = \begin{bmatrix} c_{k+1} & c_{k+2} & \cdots & c_t \end{bmatrix}$$
(18)

将 $\{x,y\}$ 代入 SVR 模型中,训练模型,并用 PSO 对 模型的参数进行优化,预测部分将 x_i 作为模型的输入,得 到预测结果 y_{i} :

$$\hat{yt}_i = \begin{bmatrix} \hat{c}_{k+1} & \hat{c}_{k+2} & \cdots & \hat{c}_t \end{bmatrix}$$
(19)

并通过分析输出与测试集之间的误差指标,评估模型的精度;

4) 通过容量阈值与 RUL 的关系,得出预测的 RUL 结果,并通过分析预测 RUL 与真实 RUL 的误差,对所提 方法进行验证。

按照上述方法,可以准确捕捉容量回升的信息,实现 RUL预测,在实际应用中可以为系统的安全运行提供有 价值的信息。

1.4 评价指标

为了评估本文所提方法的预测性能,使用均方根误



Fig. 1 The method flowchart

差(root mean square error, RMSE)作为容量评估标准,使 用绝对误差(absolute error, AE)评估剩余使用寿命预测 结果,评价指标如下:

$$RMSE_{c} = \sqrt{\frac{1}{n} \sum_{i=1}^{n} \left(yt_{i} - y\hat{t}_{i}\right)^{2}}$$
(20)

 $AE_{RUL} = |R_t - R_p| \tag{21}$

式中: yt_i 表示实际电池容量; yt_i 表示预测电池容量; R_t 是真实 RUL 结果; R_p 表示 RUL 预测值。具体来说, 对于 指标 $RMSE_c$ 和 AE_{RUL} , 如果它们越接近于 0,则表示预测 精度更高。

2 实验结果分析

为了证明 CEEMDAN 结合 SVR 方法的有效性和准确性,本文采用了 NASA PCoE 提供的电池公开数据集中的#5、#6、#55、#56 电池。这些数据是通过对额定容量为 2 Ah 的 18650 锂离子电池在不同温度下进行了充放电和 阻抗测试收集的。其中 #5、#6 的环境温度为室温 (24 ℃),#55、#56 的环境温度为4℃,本文通过做对比 试验验证所建立模型的精度。

充电,在1.5 A 的恒流模式下进行充电,直到电池电 压达到4.2 V,然后继续在恒压模式下充电,直到充电电 流降至20 mA。

放电,在2A的恒流模式下进行放电,直到电池电压

分别降至 2.7、2.5、2.5 和 2.7 V。

阻抗,阻抗测量是从 0.1 Hz~5 kHz 通过电化学阻抗 谱(electrochemical impedance spectroscopy, EIS)频率 扫描。

重复的充放电循环导致电池加速老化, NASA PCoE 电池实验以电池容量退化至额定容量的 70%作为电池寿命结束(end of life, EOL)标准。本文选用#5、#6、#55、#56 锂离子电池作为研究对象。图 2 所示为各电池的容量退化曲线。



2.1 HI提取

从图 2 可以看出,随着充放电循环周期的增加,容量 逐渐衰减,因此本文认为锂离子电池的放电过程与容量 有一定的关系。而且锂离子电池的充放电电压、电流、温 度和时间在运行过程中都能方便地测量,因此通过 HI 来 预测容量。

根据上述分析,本文选取放电电压达到最低点的时间^[28]作为 HI。图 3 所示为#5 电池退化过程中不同循环 周期的放电电压曲线。整个放电过程分为放电阶段和自 充电阶段。电池放电结束后,电池放电电压趋于上升,称 为自充电。从图 3 可以看出,随着充放电周期的增加,电 压达到最低点的时间在减小。将每个周期放电电压达到 最低点的时间点提取出来,结果如图 4 所示。

为了进一步明确所提取的 HI 能否有效地表达电池 容量的退化趋势,利用 Pearson 和 Spearman 分析了 HI 与 电池容量之间的相关性。表 1 给出了#5、#6、#55 和#56 电池的 HI 相关性分析。分析结果表明,HI 的变化与容 量之间具有高度相关性,提出的 HI 是有效的,能够很好 地描述锂离子电池的容量退化过程。

2.2 容量预测结果

为了更直观地体现出本文提出的模型性能,采用一









表 1 HI 与容量相关性分析 Table 1 Correlation analysis of HI and capacity

相关性分析	电池编号				
	#5	#6	#55	#56	
Pearson	0.9998	0. 999 9	0.907 6	1.000 0	
Spearman	0.9995	0.9998	0.8713	0.9999	

步预测,分别对#5、#6、#55 和#56 电池进行 3 组对比实验。选取 NASA PCoE 提供的公开数据集中 5 号电池的 HI 为例,CEEMDAN 的结果如图 5 所示。可以看出经 CEEMDAN 分解后,不仅可以提取出退化趋势,而且捕捉 到容量回升部分,有助于提高预测模型的性能。

为了验证基于 CEEMDAN-SVR(M1)的锂离子电池 预测模型的有效性,本文设计了两个对比模型 M2 和 M3。如表 2 所示,M2 模型采用 SVR 直接建立预测模型, 而不采用 CEEMDAN 对 HI 进行分解,M3 模型采用 RVM 建立预测模型,其他步骤与 M1 模型相同。通过 M2 来分



析 CEEMDAN 在所提出的 M1 模型中的作用, M3 则用来 说明 SVR 预测容量的准确性。实验设置为#5、#6 电池选 取第 1 个周期到第 80 个周期的数据作为训练样本, 预测 起点为 81, #55、#56 电池选取第 1 个周期到第 70 个周期 的数据作为训练样本, 预测起点为 71。

表 2 提出的 3 种模型(M1~M3) 2 The proposed three models (M1~M3)

Table 2 The prop	osed three models (1911 - 1915)
模型	模型描述
M1	CEEMDAN+SVR
M2	SVR

CEEMDAN+RVM

M3

图 6 所示为不同预测模型的结果。结果表明, M1 模型的预测曲线最接近实际容量退化曲线, 与 M1 模型相比, M2 模型的预测结果随着循环次数的增加, 预测结果与实际容量的差距变大。通过比较可以得出, 利用 CEEMDAN 分解再建立预测模型是可以提高预测精度的, 同时, M3 模型利用 CEEMDAN 分解来预测, 但 M3 的预测曲线偏离了实际容量曲线, 预测效果不好。









表 3 给出了 3 组实验评估指标的对比,可以看出本 文方法的 RMSE 指标是最小的,即误差最小,预测精度最 高,这意味着在预测下一个值时会有非常小的误差,这也 为预测 RUL 奠定了良好的基础。

2.3 RUL 预测

本文以电池容量退化至额定容量的 70% 为 EOL 标准。RUL 是在电池容量达到预设失效阈值之前的剩余时

表 3 不同模型评估指标对比

Table 3 Comparison of different prediction models

模型 —		RMSE			
	#5	#6	#55	#56	
M1	0.003 1	0.007 1	0.007 9	0.002 7	
M2	0.014 4	0.011 9	0.043 0	0.003 7	
M3	0.284 8	0.056 0	0.0201	0.0714	

间长度。其中#5、#6 电池容量失效阈值为 1.4 Ah,EOL 值对应的循环周期数分别为 124、107。#55、#56 电池容 量的最大测量容量<1.4 Ah^[29],故本文只预测#55、#56 的 容量来验证所建立模型的精度。

图 7 所示为 4 个电池在不同预测起点下 M1 模型的 预测效果,从总体上看,每个起始点的预测结果都非常接 近实际值,不同的预测起始点对预测结果也没有明显的 影响。表明本文所提出的 M1 模型具有很高的精确性和 稳定性。

通过与 EOL 阈值的比较,可以得到 RUL 预测结果。 可以看到预测起点越晚,预测结果越精确。表 4 给出了 M1 模型在#5、#6 电池的不同起始点的容量和 RUL 预测 结果,和#55、#56 电池的不同起始点的容量预测结果,可 以看到,#55 电池由于温度影响,预测精度低于另外 3 个 电池,但总体模型 M1 受预测起点的影响相对较小,预测





图 7 四个电池不同起点预测结果

Fig. 7 Results predicted by different models

性能相对稳定。与已有的方法相比,通过对 HI 分解再进行预测,提高了预测精度,验证了该方法的有效性。

表 4 M1 模型不同电池不同起始点结果分析

 Table 4 Analysis of different starting points of different batteries in M1 model

电池编号	预测起点	真实 RUL	预测 RUL	AE	RMSE
#5	71	54	49	5	0.004 9
	81	44	43	1	0.003 1
	91	34	33	1	0.002 6
	101	24	24	0	0.002 1
#6	71	37	38	1	0.013 8
	81	27	27	0	0.007 1
	91	17	17	0	0.007 0
	101	7	7	0	0.003 5
#55	51	-	-	-	0.018 6
	61	-	-	-	0.016 8
	71	-	-	-	0.015 3
#56	51	-	-	-	0.009 8
	61	-	-	-	0.004 8
	71	-	-	-	0.002 7

3 结 论

锂离子电池的 RUL 预测是 PHM 的关键组成部分, 准确预测锂离子电池的 RUL 可以保证系统运行的安全 性和稳定性。因此,本文提出了一种基于 CEEMDAN 和 SVR 的方法来预测锂离子电池的 RUL。此外,利用 NASA 的部分电池数据进行了仿真,验证了本文方法的 RUL 预测性能。与只用 SVR 和 CEEMDAN 与 RVM 结合 的方法相比,结果表明,该方法能提高锂离子电池的 RUL 的预测精度。

考虑到实际生产生活中电池充放电过程的充满随机 性,故下一步,本课题将重点针对更贴合实际情况的电池 充放电数据(如 NASA 中的 RW 类型实验数据,该数据集 为通过随机生成的电流工况下连续循环的电池数据集) 对锂离子电池的 RUL 预测做进一步的研究。

参考文献

 [1] 刘大同,周建宝,郭力萌,等. 锂离子电池健康评估 和寿命预测综述 [J]. 仪器仪表学报, 2015, 36(1):
 1-16.

> LIU D T, ZHOU J B, GUO L M, et al. Survey on lithium-ion battery health assessment and cycle life estimation [J]. Chinese Journal of Scientific Instrument, 2015, 36(1): 1-16.

[2] 雷津, 邓磊, 李小谦, 等. 基于 EKF 的船舶动力锂电 池剩余容量估算 [J]. 电子测量技术, 2016, 39(12): 85-88.

> LEI J, DENG L, LI X, et al. Accurate SOC estimation of the power Li-ion battery based on EKF [J]. Electronic Measurement Technology 2016, 39(12): 85-88.

[3] 王文靖,梁旭,温菲菲.无人机机载发电机故障诊断 技术研究 [J]. 国外电子测量技术,2016,35(8): 94-98.

> WANG W J, LIANG X, WEN F F. Study on fault diagnosis technology of UAV airborne generators [J]. Foreign Electronic Measurement Technology, 2016, 35(8): 94-98.

- [4] PENG J, ZHOU Z B, WANG J Q, et al. Residual remaining useful life prediction method for lithium-ion batteries in satellite with incomplete healthy historical data [J]. IEEE Access, 2019(7): 127788-127799.
- [5] 印学浩,宋宇晨,刘旺,等.基于多时间尺度的锂离子电池状态联合估计[J]. 仪器仪表学报,2018, 39(8):118-126.

YIN X H, SONG Y CH, LIU W, et al. Multi-scale state joint estimation for lithium-ion battery [J]. Chinese Journal of Scientific Instrument, 2018, 39 (8): 118-126.

- [6] ZHANG Y, XIONG R, HE H, et al. Lithium-ion battery remaining useful life prediction with box-cox transformation and monte carlo simulation [J]. IEEE Transactions on Industrial Electronics, 2019, 66(2): 1585-1597.
- [7] ZHANG X, MIAO Q, LIU Z. Remaining useful life prediction of lithium-ion battery using an improved UPF method based on MCMC [J]. Microelectronics Reliability, 2017, 75: 288-295.
- [8] LONG B, LI X, GAO X, et al. Prognostics comparison of lithium-ion battery based on the shallow and deep neural Networks model [J]. Energies, 2019, 12(17):3271.
- [9] HU X S, LI S B, PENG H. A comparative study of equivalent circuit models for Li-ion batteries [J]. Journal of Power Sources, 2012, 198: 359-367.
- [10] LYU C, LAI Q Z, GE T F, et al. A lead-acid battery's remaining useful life prediction by using electrochemical model in the Particle Filtering, framework [J]. Energy, 2017, 120: 975-984.
- [11] DONG G Z, CHEN Z H, WEI J W, et al. Battery health prognosis using brownian motion modeling and particle filtering [J]. IEEE Transactions on Industrial Electronics, 2018, 65(11): 8646-8655.
- [12] 姜媛媛, 刘柱, 罗慧, 等. 锂电池剩余寿命的 ELM 间 接预测方法 [J]. 电子测量与仪器, 2016, 30(2): 179-185.

JIANG Y, LIU ZH, LUO H, et al. ELM indirect prediction method for the remaining life of lithium-ion battery [J]. Journal of Electronic Measurement and Instrument, 2016, 30(2): 179-185.

- [13] 张焱,汤宝平,熊鹏. 多尺度变异粒子群优化 MK-LSSVM 的轴承寿命预测 [J]. 仪器仪表学报, 2016, 37(11): 2489-2496.
 ZHANG Y, TANG B P, XIONG P. Rolling element bearing life prediction based on multi-scale mutation particle swarm optimized multi-kernel least square support vector machine [J]. Chinese Journal of Scientific Instrument, 2016, 37(11): 2489-2496.
- [14] ZHOU Y P, HUANG M H. Lithium-ion batteries remaining useful life prediction based on a mixture of empirical mode decomposition and ARIMA model [J]. Microelectronics Reliability, 2016, 65: 265-273.
- [15] QU J, LIU F, MA Y, et al. A Neural-network-based method for RUL prediction and SOH Monitoring of lithium-ion battery [J]. IEEE Access, 2019 (7): 87178-87191.

- [16] DONG H C, JIN X N, LOU Y B, et al. Lithium-ion battery state of health monitoring and remaining useful life prediction based on support vector regression-particle filter [J]. Journal of Power Sources, 2014, 271: 114-123.
- [17] ZHANG X, MIAO Q, LIU Z W. Remaining useful life prediction of lithium-ion battery using an improved UPF method based on MCMC [J]. Microelectronics Reliability, 2017, 75: 288-295.
- [18] 吴祎, 王友仁. 基于变分模态分解和高斯过程回归的 锂离子电池剩余寿命预测方法 [J]. 计算机与现代 化, 2020(2): 83-88.
 WU Y, WANG Y. Remaining useful life prediction of lithium-ion batteries based on VMD and GPR algorithm [J]. Computer and Modernization, 2020(2): 83-8.
- [19] LIU D, ZHOU J, LIAO H, et al. A health indicator extraction and optimization framework for lithium-ion battery degradation modeling and prognostics [J]. IEEE Transactions on Systems Man Cybernetics-Systems, 2015, 45(6): 915-28.
- [20] ZHOU Y P, HUANG M H, CHEN Y P, et al. A novel health indicator for on-line lithium-ion batteries remaining useful life prediction [J]. Journal of Power Sources, 2016, 321: 1-10.
- [21] CHEN L P, XU L J, ZHOU Y L. Novel approach for lithium-ion battery on-line remaining useful life prediction based on permutation entropy [J]. Energies, 2018, 11(4):820.
- [22] ZHAO Q, QIN X L, ZHAO H B, et al. A novel prediction method based on the support vector regression for the remaining useful life of lithium-ion batteries [J]. Microelectronics Reliability, 2018, 85: 99-108.
- [23] 贾逸伦,龚庆武,李俊雄,等. 基于 CEEMDAN 与量 子粒子支持向量机的电力负荷组合预测 [J]. 电测与 仪表, 2017, 54(1): 16-21.
 JIA Y, GONG Q, LI J, et al. The power load combined forecasting based on CEEMDAN and QPSO-SVM [J].
 Electrical Measurement & Instrumentation, 2017, 54(1): 16-21.
- [24] COLOMINAS M A, SCHLOTTHAUER G, TORRES M
 E. Improved complete ensemble EMD: A suitable tool for biomedical signal processing [J]. Biomedical Signal Processing and Control, 2014, 14: 19-29.
- [25] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]. 2011 IEEE International Conference on Acoustics, Speech and Signal

Processing (ICASSP), 2011.

[26] 王树坤,黄妙华,刘安康,等. 基于 GA-SVR 模型的 健离子电池剩余容量预测 [J]. 汽车技术, 2016,(10):53-56,62.

WANG SH K, HUANG M H, LIU AN K, et al. Prediction of li-ion battery's remaining capacity based on GA-SVR algorithm [J]. Automobile Technology, 2016, (10): 53-56,62.

 [27] 丁阳征, 贾建芳. 改进 PSO 优化 ELM 预测锂离子电 池剩余寿命 [J]. 电子测量与仪器学报, 2019, 33(2): 72-79.

> DING Y ZH, JIA J F. Improved PSO optimized extreme learning machine predicts remaining useful life of lithiumion battery [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 72-79.

[28] JIA J, LIANG J, SHI Y, et al. SOH and RUL prediction of lithium-ion batteries based on gaussian process regression with indirect health indicators [J]. Energies, 2020, 13(2):375.

[29] LI P, ZHANG Z, XIONG Q, et al. State-of-health estimation and remaining useful life prediction for the lithium-ion battery based on a variant long short term memory neural network [J]. Journal of Power Sources, 2020, 459:228069.

作者简介



杨彦茹,2018年于北京交通大学海 滨学院获得学士学位,现为中北大学硕 士研究生,主要研究方向为故障预测与 健康管理、锂离子电池的剩余使用寿命 预测。

E-mail:764999306@ qq. com

Yang Yanru received her B. Sc. degree from Beijing Jiaotong University Haibin College in 2018. Now she is a M. Sc. candidate at North China University. Her main interests include prognostics health management and prediction of the remaining life of lithium-ion batteries.