

DOI:10.11918/202211032

粒子滤波和 GRU 神经网络融合的锂电池 RUL 预测

贺 宁¹, 张思媛¹, 李若夏², 高峰¹, 王家栋³

(1. 西安建筑科技大学 机电工程学院, 西安 710055; 2. 西安建筑科技大学 信息与控制工程学院, 西安 710055;
3. 浙江中控技术股份有限公司, 杭州 310000)

摘要: 随着锂电池在移动电子设备和电动汽车等领域中得到广泛应用, 其剩余使用寿命 (remaining useful life, RUL) 的精确预测对锂电池的健康管理更具重要意义。本文提出一种基于粒子滤波 (particle filter, PF) 和门控循环单元 (gated recurrent unit, GRU) 神经网络融合 (PF-GRU) 的预测方法预测锂电池的 RUL。这种融合方法结合了 PF 在估计 RUL 概率分布上的优势以及 GRU 能够进行时间序列长期预测的能力, 获得融合的预测结果。再利用每个预测周期的容量预测结果, 采用带移动窗口迭代更新训练数据集的方法对 GRU 模型进行再训练, 提高了 GRU 的长期预测性能。以上预测步骤迭代进行, 直到容量衰减至寿命阈值以下。最后将粒子代表的预测结果外推至寿命阈值, 得到电池 RUL 分布直方图。本文采用美国 NASA 卓越诊断学中心 (PCoE) 实验室所提供的锂电池数据对所提方法进行验证, 将所提出的融合方法与 GRU、PF 和无窗口移动融合方法进行 RUL 预测比较。实验结果表明, 本文所提出的融合方法具有良好的性能, 在状态和参数估计、RUL 预测方面明显优于 PF 和无窗口移动融合方法, 预测精度均高于其他 3 种预测方法。

关键词: 锂电池; 剩余使用寿命; 粒子滤波; GRU 神经网络; 融合方法

中图分类号: TM912

文献标志码: A

文章编号: 0367-6234(2024)05-0142-10

RUL prediction of lithium battery based on particle filter and GRU neural network fusion

HE Ning¹, ZHANG Siyuan¹, LI Ruoxia², GAO Feng¹, WANG Jiadong³

(1. School of Mechanical and Electrical Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China;
2. School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China;
3. Zhejiang Supcon Technology Co. Ltd, Hangzhou 310000, China)

Abstract: As lithium-ion batteries are widely used in mobile electronics and electric vehicles, accurate prediction of their remaining useful life (RUL) is of great importance for health management of lithium batteries. A prediction method based on particle filter (PF) and gated recurrent unit (GRU) neural network fusion method (PF-GRU) is proposed to predict the RUL of lithium batteries. This fusion method combines the advantages of PF in estimating the probability distribution of RUL and the ability of GRU to perform long-term prediction of time series to obtain the fusion prediction result. Using the capacity prediction results of each prediction period, the GRU model is retrained by iteratively updating the training dataset with a sliding window, which improves long-term prediction performance of GRU. The above prediction steps are iteratively performed until the capacity decays below the lifetime threshold. Finally, prediction results represented by particles are extrapolated to the lifetime threshold, and RUL distribution histogram of the battery is obtained. The lithium battery data provided by the NASA prognostics center of excellence (PCoE) laboratory is adopted to verify the proposed method, which compares the proposed fusion method with GRU, PF and fusion method without sliding window for RUL prediction. Experimental results show that the proposed fusion method has good performance, which is obviously better than PF and fusion method without sliding window in terms of state and parameter estimation and RUL prediction accuracy.

Keywords: lithium-ion battery; remaining useful life; particle filter; GRU neural network; fusion method

收稿日期: 2022-11-09; 录用日期: 2023-01-28; 网络首发日期: 2023-03-31

网络首发地址: <http://kns.cnki.net/kcms/detail/23.1235.T.20230331.1456.010.html>

基金项目: 国家自然科学基金(61903291); 陕西省重点研发计划项目(2022NY-094)

作者简介: 贺 宁(1989—), 男, 博士, 教授

通信作者: 李若夏, rli@xauat.edu.cn

锂电池与传统的镍氢、镍铬等电池相比,具有自重轻、能量密度高和循环寿命长等特点,被广泛应用于生活^[1]。但由于外部环境复杂和内部电极损失等情况,锂电池会产生容量衰减、热稳定性下降等问题,增大了锂电池的使用风险。因此,对锂电池的健康监测已成为一项重要课题^[2]。

锂电池的剩余使用寿命(remaining useful life, RUL)通常定义为在电池达到寿命阈值之前的充放电循环周期^[3]。RUL预测是电池管理系统(battery management system, BMS)电池状态估计的重要组成部分, RUL的精确预测可以有效降低锂电池的使用风险,故RUL预测准确度的提升具有重要意义。针对锂电池RUL的预测,目前常用的方法大致分为基于模型、基于数据驱动和基于融合方法的预测方法^[3]。

模型法分为退化机理模型、等效电路模型和经验退化模型^[4-5]。退化机理模型通过电池内部的物理化学过程,建立电池老化模型。文献[6]提出一种控制导向单粒子模型,并基于最小二乘和递归参数法估计锂电池的老化参数。等效电路模型搭建由电气元件构成的模型来等效或近似电池内部工作原理。文献[7]基于改进的Randles等效电路模型,通过功率和容量衰减预测RUL。机理模型和等效电路模型复杂度高、难度大,因此较少使用。经验退化模型通过输入与输出之间的内在关联,建立逼近规律的统计模型^[4]。经验模型通常与滤波算法结合进行RUL预测,常用的有卡尔曼滤波(Kalman filter, KF)、粒子滤波(particle filter, PF)等。文献[8]基于联合预测模型利用噪声状态信号和约束KF进行RUL预测。文献[9]基于单指数经验模型采用PF预测RUL。用经验模型建模预测RUL时,会增大对模型的依赖,导致鲁棒性降低。

数据驱动法不需要考虑电池内部运行及失效机制,仅需要大量数据集,分析其隐含的电池状态信息来预测RUL。常用的数据驱动法有支持矢量机(support vector machine, SVM)、相关矢量机(relevance vector machine, RVM)和人工神经网络(artificial neural network, ANN)等。文献[10]基于SVM在线监测电动汽车的电池退化情况。文献[11]基于RVM进行RUL预测。数据驱动法需要大量的训练数据,计算复杂度较高,对于SVM这样的人工智能算法,核的选择和参数设置对预测精度影响很大。

目前,基于融合方法的RUL预测逐渐成为热点。融合型算法可以分为模型与数据驱动的融合算法和不同数据驱动算法之间的互补或加权融合^[4]。

融合型预测方法可以结合不同算法的特点,发挥不同算法的优势,从而获得更好的预测精度和鲁棒性。文献[12]以PF为核心,以双指数模型作为状态方程,以ANN作为观测方程,估计得到电池容量退化曲线,进一步估计锂电池RUL,但作为PF观测方程的ANN引入了误差,增加了RUL预测误差。文献[13]提出PF和自回归模型相融合的RUL预测方法,但预测方法的动态更新能力不足。文献[14]将相关矢量回归得到的预测值和最新的真实残差值进行融合,构成具有时变权重的未来残差,再基于UKF对电池的RUL进行预测。文献[15]将自回归综合模型的预测值作为平方根容积KF的观测值,进而弱化了该滤波算法对经验模型的依赖性,提高了RUL的预测精度。文献[16]选取容量和等压放电时间数据,训练出容量退化CNN-LSTM模型和等压放电时间预测CNN-LSTM模型,最后结合这2个模型预测锂电池的RUL。

基于现有研究,本文采用融合型算法中的模型与数据驱动融合的算法,提出基于PF和门控循环单元(gated recurrent unit, GRU)神经网络融合的锂电池RUL预测方法。首先,利用训练数据分别建立锂电池经验退化双指数模型和GRU神经网络模型;然后,利用GRU神经网络获得预测值,并将其作为PF的观测值添加到容量退化模型中;最后,更新得到最终预测值。本文的贡献点总结为以下3点:1)采用GRU神经网络作为融合信息源之一,GRU具有结构简单、训练参数较少的特点,与跟其结构类似的长短期记忆网络(long short-term memory, LSTM)相比,GRU的训练复杂度和过拟合风险较低;2)所提的PF和GRU融合的方法在训练数据较少的情况下,仍可以具有较高的长期预测精度;3)对融合的2个模型采用带移动窗口的迭代式的训练机制,区别于许多现有研究中预测模型一成不变的状态,具有动态更新能力,能有效提高对电池长期性的容量预测的准确性。

1 锂电池RUL预测方法

1.1 粒子滤波(PF)

PF算法是基于蒙特卡罗方法和递归贝叶斯估计的滤波方法。对于锂电池这样的非线性系统,PF算法具有良好的适用性,因此,PF是现阶段应用最广泛的RUL估计方法之一。PF算法如下^[17]:

若已知非线性系统的状态空间方程为

$$\begin{cases} x_k = f(x_{k-1}, \omega_k) \\ y_k = h(x_k, \gamma_k) \end{cases} \tag{1}$$

式中: x_k 为 k 时刻的系统状态值, y_k 为 k 时刻的观测

值, f 和 h 为系统状态方程和观测方程, ω 和 γ 为系统过程噪声和观测噪声且相互独立。

1) 粒子初始化。根据先验分布 $p(x_0)$ 随机生成粒子集 $\{x_0^i\}_{i=1}^N, i=1, 2, \dots, N$ 。

2) 重要性采样。根据 $x_k^i \sim p(x_k^i | x_{k-1}^i)$ 对每个粒子进行采样。

3) 计算权重。令 $q(x_k | y_{1:k}) = p(x_k | x_{k-1})$, 得到权值 $w_k^{(i)}$ 的递归更新为

$$w_k^{(i)} = w_{k-1}^{(i)} \frac{p(y_k | x_k^{(i)}) p(x_k^{(i)} | x_{k-1}^{(i)})}{q(x_k^{(i)} | x_{k-1}^{(i)}, y_{1:k})} \quad (2)$$

式中 $p(y_k | x_k^{(i)})$ 是 $x_k^{(i)}$ 的似然估计。

4) 权重归一化。对式(2)所得 $w_k^{(i)}$ 进行归一化

$$\hat{w}_k^{(i)} = \frac{w_k^{(i)}}{\sum_{i=1}^N w_k^{(i)}} \quad (3)$$

5) 重采样。根据归一化权重的大小, 保留权重大的粒子, 舍弃权重小的粒子, 得到 k 时刻的新粒子集合 $\{x_k^i\}_{i=1}^N$, 重新分配权值, 使 $w_k^{(i)} = \frac{1}{N}$ 。

6) 状态估计。见式(4):

$$x_k = \sum_{i=1}^N \hat{w}_k^{(i)} x_k^{(i)} \quad (4)$$

1.2 GRU 神经网络

GRU 神经网络源于循环神经网络 (recurrent neural network, RNN), 传统的 RNN 存在梯度消失问题, 同时对时间距离长的数据特征信息的处理能力较弱。LSTM 神经网络作为 RNN 的一种变体, 可以学习长期依赖信息。GRU 神经网络与 LSTM 神经网络类似, 也是 RNN 的一种变体, 同样可以有效保留时间序列数据中的长期依赖性。

GRU 神经网络的结构见图 1。图 1 中, r_t 为重置门, u_t 为更新门, x_t 为 t 时刻的输入, h_t 为 t 时刻的输出, h_{t-1} 为前一时刻的隐藏状态。




图 1 GRU 神经网络结构示意图

Fig. 1 Schematic of GRU neural network structure

由图 1 可知, GRU 神经网络的工作原理如下^[18]:

1) 重置门。该门得到 0 ~ 1 之间的门控信号为

$$r_t = \sigma(W_r h_{t-1} + W_r x_t) \quad (5)$$

式中: h_{t-1} 为前一时刻的隐藏状态, x_t 为当前时刻的输入, W_r 为其各自的权重, σ 为 sigmoid 函数。

当得到门控信号之后, 按式(6)计算, 得到范围在 -1 ~ 1 之间的 $\tilde{h}_t$ 为

$$\tilde{h}_t = \tanh[r_t \odot (W_h' h_{t-1} + W_x' x_t)] \quad (6)$$

式中: W_h' 、 W_x' 为 h_{t-1} 、 x_t 各自可训练的权重; $\odot$ 为 Hadamard 乘法; $\tanh$ 为非线性激活函数。

2) 更新门。更新门和重置门的计算形式相同, 但对每个门来说, 权重矩阵与输入状态和隐藏状态相乘的结果都是唯一的, 这表明每个门的最终矢量是不同的。具体为

$$u_t = \sigma(W_z h_{t-1} + W_z x_t) \quad (7)$$

式中 W_z 为更新门输出对应的权重矩阵。

然后, 按式(8)合并输出 h_t 为

$$h_t = u_t \odot h_{t-1} + (1 - u_t) \odot \tilde{h}_t \quad (8)$$

式中: u_t 为进行选择性的记忆, $(1 - u_t)$ 为进行选择性的遗忘。

GRU 神经网络相较于 LSTM 神经网络的优势在于, GRU 使用同一个门控 u_t 便可以同时进行选择性的记忆和遗忘, 而 LSTM 则需要多个门控。GRU 的输入输出结构与标准的 RNN 相似, 而其内部思想则与 LSTM 相似。与 LSTM 结构相比, GRU 的内部少了一个“门控”, 相关参数也比 LSTM 少, 但却能够达到与 LSTM 相当的效果。故本文选择计算能力高且时间成本低的 GRU 神经网络作为融合方法的神经网络部分。

1.3 融合方法

基于融合方法的锂电池 RUL 预测已经获得了越来越多研究者的关注, 本文采用一种经验模型与数据驱动相融合的结构, 提出一种迭代式的基于 PF 和 GRU 神经网络 (PF-GRU) 的锂电池 RUL 预测方法。该方法与现有融合方法相比, 考虑了训练数据较少情况下的长期预测效果, 且该方法的运算效率较高。

1.3.1 基于 PF-GRU 的融合方法

对于 PF-GRU 的融合方法的锂电池 RUL 预测过程, 需建立状态转移方程和观测方程:

$$x_k = [a_k; b_k; c_k; d_k] \quad (9)$$

$$\begin{cases} a_k = a_{k-1} + \omega_a, \omega_a \sim N(0, \sigma_a) \\ b_k = b_{k-1} + \omega_b, \omega_b \sim N(0, \sigma_b) \\ c_k = c_{k-1} + \omega_c, \omega_c \sim N(0, \sigma_c) \\ d_k = d_{k-1} + \omega_d, \omega_d \sim N(0, \sigma_d) \end{cases} \quad (10)$$

$$Q_k = a_k * \exp(b_k * k) + c_k * \exp(d_k * k) + \gamma_k, \gamma_k \sim N(0, \sigma_Q) \quad (11)$$

式中: a 、 b 、 c 、 d 为电池的内部参数, 也为状态量, 电池容量作为观测量; k 为电池的充放电循环周期; ω 、 γ 分别为过程噪声和测量噪声, 它们都是高斯噪声; Q_k 是 k 循环周期的容量观测值, 该状态估计问题的外部测量值 y^{obs} 由 GRU 神经网络的预测值提供, 即 $y^{\text{obs}} = g(V, I, t)$; V 、 I 、 t 分别为电池充电电压、放电电流和放电时间。本文在预测阶段的每一个预测周期中采用 PF 的滤波方法利用 GRU 神经网络的预测值对双指数经验模型的参数 a 、 b 、 c 、 d 进行更新, 再利用更新后的参数计算新的容量预测值, 从而实现

GRU 神经网络提供的预测信息与双指数经验模型提供的预测信息的融合。

在获得融合后的更新参数后, 当电池达到所设置的寿命阈值 E_{OL} 时, 由式 (12) 便可得到充放电循环周期 L_k

$$E_{\text{OL}} = a_k * \exp(b_k * L_k) + c_k * \exp(d_k * L_k) \quad (12)$$

进一步可以确定在循环周期 L_k 时的 RUL 分布, 见式 (13), 由此就可以预测电池的 RUL

$$P(L_k | Q_{1:k}) \approx \sum_{i=1}^N w_k^{(i)} \delta(L_k - L_k^{(i)}) \quad (13)$$

本文所提出的基于 PF-GRU 融合方法对锂电池的容量状态估计和 RUL 预测方法的流程见图 2。




图 2 PF-GRU 融合方法流程

Fig. 2 Flow chart of PF-GRU fusion method

PF-GRU 算法分为训练阶段和预测阶段。为了描述方便, 有如下定义: 预测起点为 s ; $\mathbf{D}_{\text{train}(s)}$ 是 GRU 模型训练的训练数据矢量, $\mathbf{D}_{\text{test}}$ 是 GRU 模型的测试数据矢量, 根据实验电池的数据集总长度, #5、#6、#7 电池的 s 设置为 84, 即 #5、#6、#7 电池的 $\mathbf{D}_{\text{train}(s)}$ 为各自的前 84 组数据, #18 电池的 s 设置为 66, 即 #18 电池的 $\mathbf{D}_{\text{train}(s)}$ 为其前 66 组数据; 在 $\mathbf{D}_{\text{train}(s)}$ 中, 锂电池的充电电压、放电电流以及放电时间 3 个特征作为输入量, 锂电池的容量作为输出量, $1 \sim s$ 步周期的容量用 $C_1, C_2, C_3, \dots, C_s$ 表示; 在预测阶段, GRU 模型每个循环周期的输出为 $Q_{p_{s+i}}$, 表示第 $s+i$ 步的预测容量。

步骤如下:

- 1) 从电池数据集中提取电池的充电电压、放电电流、放电时间数据和容量数据并进行预处理。
- 2) 设置预测起点 s 和寿命阈值。将循环容量数据集分为两部分, 将循环周期 $1 \sim s$ 步的电池充电电压、放电电压、放电时间数据和容量数据作为 GRU 模型和双指数经验模型的训练数据集 $\mathbf{D}_{\text{train}(s)}$ 。
- 3) 训练阶段开始。用 $\mathbf{D}_{\text{train}(s)}$ 训练 GRU 模型, 同时 $\mathbf{D}_{\text{train}(s)}$ 也用于建立双指数经验模型。
- 4) 预测阶段开始。在第 $s+1$ 个循环周期, 用 GRU 模型预测 $s+1$ 循环周期时的电池容量, 并命名为 $Q_{p_{s+1}}$ 。
- 5) 针对由式 (9)、(10) 组成的状态空间模型, 将

如图 2 所示, 基于 PF-GRU 的融合方法的详细

$Q_{p_{s+1}}$ 作为 PF 中的测量值,利用 PF 算法估计模型状态 $[a_k; b_k; c_k; d_k]$,从而由此得到优化后的容量预测值 Q_{s+1} 。

6) 使用优化的容量预测值 Q_{s+1} 更新 GRU 模型的训练数据集 D_{train} ,再利用新的训练数据集 D_{train} 重新训练 GRU 神经网络。

7) 重复执行步骤 4 至步骤 5,直到预测步长达到数据集总长度,循环结束。最后外推至寿命阈值,得到锂电池容量退化曲线和 RUL 的分布。

1.3.2 GRU 神经网络的迭代训练

为提高融合方法的预测精度,在预测阶段对 GRU 模型采用了带移动窗口的迭代训练机制,能够使整个预测阶段的经验模型和 GRU 神经网络相互学习,保持动态更新。具体来说,本文将最新的融合信息插入 GRU 的训练数据集中,使之保持迭代更新。该方法的详细过程描述如下:

1) 对电池数据集进行预处理。

2) 设置预测起点 s ,得到的 $D_{\text{train}(s)}$ 为电池前 s 组数据,即 $D_{\text{train}(s)}$ 由 $C_1, C_2, \dots, C_s$ 组成,剩下的 $C_{s+1}, C_{s+2}, \dots, C_{168}$ 作为测试集(以 #5 号电池数据集为例)。

3) 利用训练数据集 $D_{\text{train}(s)}$ 对 GRU 模型进行训练,得到第 $s+1$ 步 GRU 模型的预测值 $Q_{p_{s+1}}$ 。

4) 将 $Q_{p_{s+1}}$ 作为 PF 的观测值输入 PF 并进行滤波,得到第 $s+1$ 步融合后的优化估计值 Q_{s+1} 。

5) 将 Q_{s+1} 加入 GRU 模型的 $D_{\text{train}(s)}$,生成新的训练数据集 $D_{\text{train}(s+1)}$ 。更新后的 $D_{\text{train}(s+1)}$ 由 $C_2, C_3, \dots, C_s, Q_{s+1}$ 组成。

6) 从第 $s+2$ 步到第 168 步反复执行步骤 3 至步骤 5,直到预测步长达到数据集总长度。

2 实验数据集和评价标准

2.1 实验数据集

采用来自美国 NASA 的 PCoE 实验室的公开锂电池数据集,验证所提出方法预测锂电池 RUL 的准确性。选择标号为 B0005、B0006、B0007、B0018 的 4 块电池数据,本文使用 #5、#6、#7、#18 代表上述电池标号。对所获取的电池原始数据进行分析,原始数据集中的个别数据不是一次完整的充放电循环,存在缺失充电或放电状态数据的情况,对这些异常值进行删除,最终分别得到 #5、#6、#7 和 #18 电池的 168、168、168 和 132 个充放电循环容量数据。4 块电池均为钴酸锂电池,额定容量均为 2 Ah,且均在 24 °C 的室温下进行实验。在 1.5 A 恒流状态下充电至电压达到 4.2 V,然后保持恒压,直到电流降至 20 mA;然后在 2 A 左右的恒流下进行放电至电池

电压分别降至 2.7、2.5、2.2 和 2.5 V;最后进行阻抗检测,完成一个充放电周期。重复上述过程,直到电池容量下降到电池寿命阈值时,实验停止。

本次实验, #5、#6、#18 电池寿命阈值定为额定容量的 70% (即容量达到 1.4 Ah), #7 电池寿命阈值定为额定容量的 72% (即容量达到 1.44 Ah)。#5、#6、#7 和 #18 电池容量随充放电循环的变化见图 3。




图 3 #5、#6、#7、#18 电池容量退化曲线

Fig. 3 Capacity degradation curve of #5, #6, #7, #18 batteries

2.2 评价标准

为了更好地说明本文所提出的 PF-GRU 融合方法的准确性,通过评价指标预测误差 P_E 和均方根误差 R_{RMSE_Q} (root mean square error, RMSE) 来评价模型精度。 P_E 定义为预测得到的 RUL 和实际 RUL 差值的绝对值,见式 (14):

$$P_E = |R_{\text{RUL}_{\text{pre}}} - R_{\text{RUL}_{\text{real}}}| \quad (14)$$

如式 (15) 所示, R_{RMSE_Q} 反映了整个预测过程中对电池容量预测结果相对实验测量值的误差,数值越小,表示预测曲线与实际曲线越来越接近。

$$R_{\text{RMSE}_Q} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y^{(i)} - \hat{y}^{(i)})^2} \quad (15)$$

3 仿真结果与分析

3.1 参数设置

本文通过对 #5、#6、#7、#18 电池数据集分别进行 4 组仿真,其中每一组仿真都使用 GRU、PF、PF-GRU (无移动窗口) 和 PF-GRU (有移动窗口) 共 4 种方法对同一电池进行预测。4 组仿真的粒子数量均设置为 200。同一电池用 PF、PF-GRU (无移动窗口) 和 PF-GRU (有移动窗口) 预测时使用相同的初始粒子集,即模型初始参数和噪声保持一致。首先,利用 MATLAB 曲线拟合工具箱分别对 #5、#6、#7 和 #18 电池的训练数据集中的容量数据进行拟合,将目标函数选定为双指数函数,从而获得双指数模型的

参数值,将该估计值作为 PF 估计的初始值。得到的初始参数拟合值见表 1。

表 1 PF 初始参数
Tab. 1 Initial parameters of PF

电池编号	a	b	c	d
#5	1.782 00	-0.001 936	0.105 50	-0.001 934
#6	1.995 00	-0.003 900	0.067 21	-0.004 129
#7	1.808 00	-0.001 923	0.126 40	-0.001 848
#18	0.091 79	-0.057 850	1.781 00	-0.001 894

通过仿真调试,过程噪声 σ_a 、 σ_b 、 σ_c 、 σ_d 和测量噪声 σ_Q 取值设置见表 2。

表 2 噪声参数
Tab. 2 Noise parameters

电池编号	$\sigma_a/10^{-4}$	$\sigma_b/10^{-4}$	$\sigma_c/10^{-4}$	$\sigma_d/10^{-5}$	$\sigma_Q/10^{-3}$
#5	10	1	1	1	1
#6	10	1	1	1	1
#7	10	1	1	1	1
#18	1	1	10	1	10

根据文献[3]对用 4 块电池的训练集数据对 GRU 模型进行训练。GRU 神经网络由输入层、隐藏层和输出层组成,使用标准前馈神经网络。采用 Adam 优化器,学习率为 0.000 5,为防止梯度爆炸,将梯度阈值设置为 1。通过调整超参数进行重复训练,最终得到的 GRU 模型训练超参数见表 3。

表 3 GRU 的训练超参数设置
Tab. 3 Training hyper parameter settings of GRU

参数	数值
最大步长	50
初始学习率	0.000 5
学习速率下降周期	25
学习速率下降因子	0.2

3.2 基于 PF-GRU 的锂电池 RUL 预测仿真结果

根据 4 块电池的有效数据量,#5、#6、#7 电池的预测点设置为第 84 个周期,#18 电池的预测点设置为第 66 个周期。由 4 种方法得到的锂电池容量退化的预测结果见图 4~7。

结合图 4~7 以及表 5 所列出的 4 种方法预测结果的 RMSE 可以看出,与 PF、GRU、PF-GRU(无移动窗口)融合方法相比,本文所提出的 PF-GRU(有

移动窗口)融合方法可以更好地近似锂电池的真实退化过程,预测结果不仅最接近锂电池的真实容量值,而且预测出的容量值呈波动状态,更加接近真实容量值。由图 4~7 可以观察到,虽然 2 种 PF-GRU 融合方法的预测精度都高于单个算法,但有移动窗口的融合方法明显比无移动窗口的融合方法预测效果更好。




图 4 对#5 电池容量的预测结果
Fig. 4 Prediction results of #5 battery capacity




图 5 对#6 电池容量的预测结果
Fig. 5 Prediction results of #6 battery capacity




图 6 对#7 电池容量的预测结果
Fig. 6 Prediction results of #7 battery capacity




图 7 对#18 电池容量的预测结果

Fig.7 Prediction results of #18 battery capacity

同时,给出最后一个循环周期的双指数经验模型参数 a 、 b 、 c 、 d 更新值,见表 4。

表 4 最后一周期的经验模型参数值

Tab.4 Parameter value of empirical model in the last cycle

电池编号	a	b	c	d
#5	1.607 1	-0.001 7	0.103 1	-0.000 818
#6	1.789 4	-0.003 0	0.144 9	-0.003 100
#7	1.798 5	-0.001 9	0.100 3	-0.000 855
#18	0.094 5	-0.055 1	1.671 2	-0.001 800

接下来,对于 PF 和 PF-GRU(有移动窗口)融合预测方法,本文根据有效粒子所代表的参数值外推至寿命阈值,进行锂电池的 RUL 预测,绘制出的直方图见图 8~11。

4 种预测方法之间的详细比较结果见表 5。





图 8 #5 电池 RUL 分布的预测

Fig.8 RUL distribution prediction of #5 battery





图 9 #6 电池 RUL 分布的预测

Fig.9 RUL distribution prediction of #6 battery




图 10 #7 电池 RUL 分布的预测

Fig. 10 RUL distribution prediction of #7 battery




图 11 #18 电池 RUL 分布的预测

Fig. 11 RUL distribution prediction of #18 battery

表 5 4 种电池锂电池 RUL 预测结果

Tab. 5 RUL prediction results of four kinds of lithium batteries

电池编号	预测方法	RUL 真实值	RUL 预测值	P_E	R_{RMSE_Q}
#5	GRU	41	78	37	0.067 3
	PF		33	8	0.049 4
	PF-GRU(无移动窗口)		47	6	0.034 2
	PF-GRU(有移动窗口)		38	3	0.019 8
#6	GRU	25	33	8	0.063 9
	PF		19	6	0.826 0
	PF-GRU(无移动窗口)		30	5	0.049 3
	PF-GRU(有移动窗口)		23	2	0.024 6
#7	GRU	63	—	—	0.076 5
	PF		50	13	0.038 5
	PF-GRU(无移动窗口)		72	9	0.027 5
	PF-GRU(有移动窗口)		62	1	0.017 0
#18	GRU	31	18	13	0.045 9
	PF		26	5	0.058 5
	PF-GRU(无移动窗口)		35	4	0.043 4
	PF-GRU(有移动窗口)		31	0	0.029 3

由表 5 得出以下结论,首先从对电池 RUL 的预测结果上看,无论有无移动窗口,PF-GRU 融合方法的预测误差都低于单个算法,同时有移动窗口的 PF-GRU 更进一步地缩小了预测误差,预测出的 RUL 最接近于真实值,而 GRU 在本次实验中未能对#7 电池的 RUL 做出估计,其长期性的预测性能稳定性较低。其次,从对电池容量预测结果的 RMSE 上看,本文所提出的融合方法的预测精度明显高于其他方法。最后综合 RUL 和 RMSE 的预测结果来看,本文提出的预测算法的误差最小,精度最高,对锂电池 RUL 具有良好的预测性能。

3.3 不同算法预测所需时长对比仿真

本部分以#5 电池为研究对象,用本文仿真所用到的 4 种方法和同样采用带移动窗口迭代训练的 PF-LSTM 进行仿真,记录各自的预测所需时间以及容量和 RUL 的预测,结果见表 6。其中,预测所需时间是由 5 种方法各进行了 10 次训练,取 10 次仿真时间的平均值,见表 6 第 2 列。

表 6 #5 电池的预测精度和所需时间结果
Tab. 6 Prediction accuracy and required time results of #5 battery

方法	平均预测 时间/s	预测的 R_{RMSE_Q} 平均值	预测的 RUL 平均值误差
PF-GRU (有移动窗口)	72.845	0.019 4	2
PF-LSTM (有移动窗口)	113.430	0.108 7	9
PF-GRU (无移动窗口)	1.109	0.036 6	9
PF	1.933	0.103 6	11
GRU	1.279	0.071 7	34

从表 6 的对比结果看,可以得到以下结论:

1) 由于存在移动窗更新迭代机制,有移动窗的比无移动窗的平均预测时间长,但是 RMSE 和 RUL 显著提高。故相对于 RMSE 和 RUL 的预测结果精度的提高,由移动窗算法导致的预测时间的加长是可以接受的。

2) GRU 比 LSTM 更高效,这是由于 LSTM 有 3 个不同的门,参数较多,收敛时间长,导致训练会消耗大量的时间,而 GRU 只含有 2 个门控,结构更为简单。

综上所述,本文提出的 PF-GRU 融合算法具有如下优点:1) 运算效率高,一方面是由于 GRU 结构简单,训练参数较少,另一方面是由于 PF 对强非线性模型的状态估计有着很高的效率和精度。2) 提出的融合方法可以在使用少样本数据集的情况下,

仍可以达到进行长期预测并保证其精度。3) 预测精度高,提出的带移动窗口的融合方法利用迭代训练机制在预测阶段对进行融合的 2 个模型迭代训练、动态更新,将 2 个模型的优势相结合,充分发挥其各自的优点,在保证模型的准确性的同时,提高了预测精度。

4 结 论

本文为提高锂电池 RUL 的预测精度,提出了一种将 PF 和 GRU 神经网络相结合的锂电池 RUL 预测的融合方法。GRU 作为一种神经网络,对时间序列预测问题具有良好的性能,同时,GRU 采用门机制解决了传统 RNN 的梯度问题和长期记忆被覆盖问题,而且 GRU 比 LSTM 参数少,拥有更快的收敛速度,更少的收敛时间,可以加速迭代过程。PF 算法能够处理非线性非高斯系统的滤波问题,对具有强非线性的锂电池经验模型的参数估计十分适用。而 PF-GRU 的融合方法集合了其所包含的 2 种方法的优点,为锂电池 RUL 的预测提供了新的可能性,另外,本文在训练阶段采用训练集迭代更新机制来实现 GRU 模型和经验模型的融合,根据最新预测的容量数据进行动态更新,保证 2 种模型的准确性。这种带移动窗口的迭代更新预测模型的方法较好地解决了现有方法对长期性的电池容量估计不准的问题,可以显著提高预测精度。通过美国 NASA PCoE 实验室提供的数据,采用 PF、GRU 神经网络、PF-GRU(无移动窗口)融合和 PF-GRU(有移动窗口)融合方法来进行 RUL 预测性能验证,通过提出预测误差和均方根误差的评价指标,对 4 种算法的预测结果进行了比较和分析。最后得出,4 块电池用本文所提方法与其他 3 种方法相比,预测误差显著降低,预测精度明显上升,从而进一步说明本文提出的融合方法可以更好地近似锂电池真实容量退化过程,明显提高对锂电池 RUL 的预测精度。RUL 预测准确率的提升,有助于 BMS 提高电池能量利用率,降低电池热失控风险,并且对电池的维保具有重要意义。

参考文献

[1] 朱丽群, 张建秋. 一种联合锂电池健康和荷电状态的新模型[J]. 中国电机工程学报, 2018, 38(12): 3613
ZHU Liqun, ZHANG Jianqiu. A new model of jointed states of charge and health for lithium batteries[J]. Proceedings of the CSEE, 2018, 38(12): 3613. DOI:10.13334/j.0258-8013.pcsee.172699

[2] 闫啸宇, 周思达, 卢宇, 等. 锂离子电池容量衰退机理与影响因素研究[J/OL]. 北京航空航天大学学报: 1. [2022-08-18]. DOI:10.13700/j. bh. 1001-5965.2021.0458

YAN Xiaoyu, ZHOU Sida, LU Yu, et al. Research on degradation mechanism and influencing factors on lithium-ion batteries[J/OL]. Journal of Beijing University of Aeronautics and Astronautics; 1. [2022-08-18]. DOI:10.13700/j. bh. 1001-5965. 2021. 0458

[3] HU Xiaosong, YANG Xin, FENG Fei, et al. A particle filter and long short-term memory fusion technique for lithium-ion battery remaining useful life prediction[J]. Journal of Dynamic Systems, Measurement, and Control, 2021, 143(6). DOI:10.1115/1.4049234

[4] 戴海峰, 张艳伟, 魏学哲, 等. 锂离子电池剩余寿命预测研究[J]. 电源技术, 2019, 43(12): 2029

DAI Haifeng, ZHANG Yanwei, WEI Xuezhe, et al. Review of remaining useful life prediction for lithium ion battery[J]. Chinese Journal of Power Sources, 2019, 43(12): 2029

[5] 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

LIU Datong, ZHOU Jianbao, GUO Limeng, et al. Survey on lithium-ion battery health assessment and cycle life estimation[J]. Chinese Journal of Scientific Instrument, 2015, 36(1): 1. DOI:10.19650/j. cnki. cjsi. 2015. 01. 003

[6] PRASAD G K, RAHN C D. Model based identification of aging parameters in lithium ion batteries[J]. Journal of Power Sources, 2013, 232: 79. DOI:10.1016/j. jpowsour. 2013. 01. 041

[7] PATTIPATI B, SANKAVARAM C, PATTIPATI K R. System identification and estimation framework for pivotal automotive battery management system characteristics [J]. IEEE Transactions on Human-Machine Systems, 2011, 41(6): 869. DOI:10.1109/tsmcc. 2010. 2089979

[8] SON J, ZHOU Shiyu, SANKAVARAM C, et al. Remaining useful life prediction based on noisy condition monitoring signals using constrained Kalman filter[J]. Reliability Engineering and System Safety, 2016, 152: 38. DOI:10.1016/j. ress. 2016. 02. 006

[9] TIAN Ye, LU Chen, WANG Zili, et al. Artificial fish swarm algorithm-based particle filter for Li-ion battery life prediction[J]. Mathematical Problems in Engineering, 2014, 2014: 1. DOI:10.1155/2014/564894

[10] KLASS V, BEHM M, LINDBERGH G. A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation[J]. Journal of Power Sources, 2014, 270: 262. DOI:10.1016/j. jpowsour. 2014. 07. 116

[11] ZHOU Yapeng, HUANG Miaohua, CHEN Yupu, et al. A novel health indicator for on-line lithium-ion batteries remaining useful life prediction[J]. Journal of Power Sources, 2016, 321: 1. DOI:10.1016/j. jpowsour. 2016. 04. 119

[12] QIN Wei, LÜ Huichun, LIU Chengliang, et al. Remaining useful life prediction for lithium-ion batteries using particle filter and artificial neural network [J]. Industrial Management & Data Systems, 2019, 120(2): 312. DOI:10.1108/imds-03-2019-0195

[13] 罗悦. 基于粒子滤波的锂离子电池剩余寿命预测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2012

LUO Yue. Research on remaining useful life prediction of lithium-ion battery with particle filter[D]. Harbin: Harbin Institute of Technology, 2012

[14] ZHENG Xiujuan, FANG Huajing. An integrated unscented Kalman filter and relevance vector regression approach for lithium-ion battery remaining useful life and short-term capacity prediction [J]. Reliability Engineering and System Safety, 2015, 144: 74. DOI:10.1016/j. ress. 2015. 07. 013

[15] 王玉斐. 一种基于 ARI 模型和 SRCKF 的融合型算法的锂电池剩余寿命预测方法[J]. 舰船电子对抗, 2019, 42(4): 117

WANG Yufei. A prediction approach of lithium battery life based on ARI model and SRCKF fusion algorithm[J]. Shipboard Electronic Countermeasure, 2019, 42(4): 117. DOI:10.16426/j. cnki. jcdzdk. 2019. 04. 026

[16] 陈赐阳, 陈德旺. 基于 CNN-LSTM 的锂电池剩余寿命(RUL)间接预测研究[J]. 电源技术, 2021, 45(5): 589

CHEN Ciyang, CHEN Dewang. Research on indirect prediction of lithium battery RUL based on CNN-LST-M[J]. Chinese Journal of Power Sources, 2021, 45(5): 589

[17] 朱文超, 许德章. 一种基于人工萤火虫群优化的改进粒子滤波算法[J]. 计算机应用研究, 2014, 31(10): 2920

ZHU Wenchao, XU Dezhang. Improved particle filter algorithm based on artificial glowworm swarm optimization[J]. Application Research of Computers, 2014, 31(10): 2920

[18] 王钊, 雷敏, 梁娇娇, 等. 基于 IPSO-GRU 的锂离子电池剩余使用寿命预测[J]. 湖南工业大学学报, 2022, 36(4): 23

WANG Po, LEI Min, LIANG Jiaojiao, et al. An IPSO-GRU-based prediction of remaining useful life of lithium-ion batteries [J]. Journal of Hunan University of Technology, 2022, 36(4): 23

(编辑 苗秀芝)