



## 基于递推门控循环单元神经网络的锂离子电池荷电状态实时估计方法

朱文凯, 周 星, 刘亚杰, 张 涛, 宋元明  
(国防科技大学系统工程学院, 湖南 长沙 410073)

**摘 要:** 锂离子电池荷电状态(state of charge, SOC)的准确估计对于保证电池系统安全运行至关重要。目前基于门控循环单元(gated recurrent unit, GRU)等循环神经网络的 SOC 估计方法得到了广泛关注, 其无需预设电池模型即可实现 SOC 准确估计。然而, 这类估计方法存在计算复杂度过高而难以在工程中实际应用的问题。针对传统 GRU 神经网络估计 SOC 时需要进行大量隐状态迭代而导致计算复杂度过高的问题, 提出了网络隐状态时序继承的递推更新方式, 通过改进 GRU 网络的输出结构, 从而实现了仅需对当前时刻采样数据进行一次网络计算即可准确获取当前时刻 SOC 估计值。与文献中报道传统 GRU 方法相比, 该递推 GRU 方法在保证 SOC 估计准确度不降低的情况下, 能减少 99% 以上的计算量, 具有较好的应用前景。此外, 针对部分应用场景中电池训练数据缺乏的问题, 方法能够结合迁移学习来快速完成网络训练。通过实验室测试数据集以及公开数据集进行验证, 该方法能对不同温度环境、不同老化状态以及不同型号的锂离子电池进行准确 SOC 估计, 其最大估计误差均不高于 3%。

**关键词:** 锂离子电池; 门控循环神经网络; 迁移学习; 荷电状态

doi: 10.19799/j.cnki.2095-4239.2022.0630

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2023) 02-570-09

## Real time state of charge estimation method of lithium-ion battery based on recursive gated recurrent unit neural network

ZHU Wenkai, ZHOU Xing, LIU Yajie, ZHANG Tao, SONG Yuanming

(College of Systems Engineering, National University of Defense Technology, Changsha 410073, Hunan, China)

**Abstract:** Accurate estimation of the state of charge of Li-ion batteries is required to guarantee the safe operation of battery systems. SOC estimation methods based on recurrent neural networks, like Gated Recurrent Unit, have recently received much attention because they can achieve accurate SOC estimation without using pre-defined battery models. However, due to their high computational complexity, these estimation methods are difficult to apply in engineering. To address the issues of high computational complexity caused by the large number of hidden state iterations required for SOC estimation in traditional GRU neural networks, a recursive update method with hidden state temporal succession is proposed, and it is possible to obtain the accurate SOC estimate at the current moment with only one network calculation of the sampled data at the current moment by improving the output structure of GRU networks. When compared to the traditional GRU method reported in the literature, this recursive GRU method can reduce the computational effort by more than 99% while maintaining SOC estimation accuracy, which has a better application prospect. Furthermore, in some application scenarios where there is a

收稿日期: 2022-10-27; 修改稿日期: 2022-11-20。

基金项目: 湖南省科技创新计划资助项目 (2021RC2074)。

第一作者: 朱文凯 (1998—), 男, 硕士研究生, 研究方向为锂离子电池状态监测, E-mail: zhuwenkai20@nudt.edu.cn; 通讯作者: 周星,

助理研究员, 研究方向为锂离子电池管理技术, E-mail: 395877464@qq.com; 张涛, 教授, 研究方向为能源互联网, E-mail: zhangtao@nudt.edu.cn。

lack of battery training data, the method can combine migration learning to quickly complete network training. The method has been validated using laboratory test datasets and public datasets, and it is capable of performing accurate SOC estimation for different temperature environments, aging states, and Li-ion battery models, with a maximum estimation error of less than 3%.

**Keywords:** lithium-ion battery; gated recurrent unit network; transfer learning; state of charge

锂离子电池因能量密度高、循环寿命长、无记忆效应等优势在电动汽车、静态储能等场景下得到了广泛应用。为了防止电池发生过充电或者过放电等异常状况，通常需要配备电池管理系统(battery management system, BMS)来监测电池的荷电状态(state of charge, SOC)<sup>[1]</sup>。电池的SOC定义为电池当前的可放电量与实际容量的比值。在实际应用中，BMS需要通过测量到的电池电压、电流、温度等信号来实时估计电池的SOC<sup>[2]</sup>。目前电池SOC估计方法主要包括以下四类，如图1所示。




图1 锂电池SOC估计方法分类  
Fig. 1 Classification of SOC estimation methods for lithium batteries

开路电压法根据开路电压(open circuit voltage, OCV)与SOC的映射关系，通过测量电池的OCV来估计电池SOC。然而，由于OCV需要电池长时间的静置才能准确测量，所以开路电压法无法用于电池SOC的实时估计。安时积分法可以通过递推公式对电池SOC进行实时估计。但是，安时积分法需要已知准确的SOC初值，且估计误差会因逐渐累计而越来越大。为了克服以上两种方法的困难，并结合两者各自优势，相关学者提出了基于模型的SOC估计方法，其通常采用机理模型<sup>[3-4]</sup>或者等效电路模型<sup>[5-7]</sup>来描述电池的动力学特性，然后结合Kalman滤波器<sup>[8-12]</sup>或龙贝格等观测器<sup>[13-15]</sup>对SOC进行估计。基于模型的SOC估计方法，能够对估计值实时校准，从而大幅提高了SOC的实时估计精度。然而，随着电池老化或者温度发生较大变化，电池的模型参数会发生改变，从而使得模型的精度下降，进而导致SOC的估计准确性下降。因此，近年来基于机器学习的电池SOC估计方法得到了相关学者的广泛

关注<sup>[16-17]</sup>。

机器学习方法是一种“黑箱模型”，其通过构建可测量数据与SOC之间的映射关系来估计电池SOC。通过将不同温度和老化状态的充放电数据加入到模型训练中，机器学习方法可以在不同温度下对不同老化状态的电池SOC进行准确估计。目前，用于估计电池SOC的机器学习方法主要包括支持向量机<sup>[18-19]</sup>、模糊逻辑<sup>[20]</sup>、高斯过程回归<sup>[21-22]</sup>、神经网络<sup>[23-25]</sup>等方法。对于采用机器学习方法进行电池SOC估计的研究已有很多，Deng等<sup>[26]</sup>利用最小二乘支持向量机与卡尔曼滤波融合的方法实现了磷酸铁锂电池的SOC和容量的联合估计；李嘉波等<sup>[27]</sup>利用梯度下降法进行高斯过程回归的参数寻优，通过仿真实验和恒流充放电实验证明了SOC估计的有效性；Zhao等<sup>[23]</sup>采用极限学习机，并利用蚁群优化算法进行神经元个数的寻优，实现了电池SOC估计。然而，以上机器学习方法对于数据处理没有时序的概念，无法较好地处理时间递归问题，而电池内部是一个时变系统，历史的充放电数据对电池SOC的影响不可忽视。因此，能够处理时间序列数据的循环神经网络(recurrent neural network, RNN)及其变体长短时记忆网络(long short-term memory, LSTM)和GRU得到了相关学者的关注和研究。其中GRU相比LSTM具有更简单的结构和更低的计算复杂度，具有一定的优势。Yang等<sup>[28]</sup>采用反编码方式，将3维的输入数据映射成了30维的数据，然后输入到GRU网络实现了SOC的有效估计；朱元富等<sup>[29]</sup>引入双向循环神经网络，增加逆序信息进行网络隐藏层训练，提高了SOC估计的准确性；李超然等<sup>[17]</sup>采用GRU神经网络与改进卡尔曼滤波器结合提高了SOC估计的鲁棒性；Tian等<sup>[16]</sup>基于GRU网络利用10分钟的充电数据与滤波方法结合实现了SOC值的准确标定。

但是，目前基于GRU神经网络的锂电池SOC估计方法对于每一时刻SOC的估计均需要构造一个电池信号的时间序列在网络内部大量迭代，这大大增加了SOC估计的计算量，而限制了其在BMS中的实

际应用。针对锂离子电池的时变特性以及GRU网络的特点,通过改进GRU网络的输出结构,提出了一种递推GRU网络,该方法可以实现序列输出,即一个时间序列的电池信号输入到递推GRU网络,可以对应得到一个时间序列的SOC估计值,从而能大大降低计算复杂度,可以满足锂电池SOC的实时估计需求。同时,针对部分应用场景中电池的标签数据缺乏,无法满足神经网络训练的情况,本工作首先通过其他电池标签数据进行预训练得到初阶网络,之后利用迁移学习进行网络参数的微调训练。通过这种方式,可以有效降低网络训练所需的标签数据量,拓宽方法的适用范围。

## 1 基于递推GRU网络的锂电池SOC实时估计模型

### 1.1 SOC实时估计模型框架

传统基于GRU神经网络方法进行锂离子电池SOC估计,本质上是建立可测量数据如电压、电流、温度等的时间序列和SOC之间的映射关系,其计算公式见式(1)。

$$\begin{cases} h_m = f_{\text{GRU}}([U_{t-m+1}, U_{t-m+2}, \dots, U_t], \\ [I_{t-m+1}, I_{t-m+2}, \dots, I_t], \\ [T_{t-m+1}, T_{t-m+2}, \dots, T_t]) \\ \text{SOC}_t = f_{\text{DNN}}(h_m) \end{cases} \quad (1)$$

式中, $m$ 为输入网络的时间序列长度, $h_m$ 为GRU网络中间变量隐状态。传统采用GRU神经网络方法估计锂电池SOC时,需要首先通过在GRU网络层中迭代计算 $m$ 次得到隐状态 $h_m$ ,然后通过全连接层得到SOC估计值。因此,传统基于GRU网络的SOC估计方法中,一个时刻的SOC估计需要输入 $m$ 个长度的采样数据经过 $m$ 次GRU网络层迭代才能完成,这对BMS的缓存和计算能力要求很高,而难以在实际工程中应用。

针对电池内部时变特性以及相邻时刻SOC值之间的联系,通过改进GRU网络的输出结构来实现计算的简化。考虑GRU网络内部隐状态的时序继承与递推更新,从而保证当前时刻SOC估计在前一时刻估计值的基础之上进行。GRU网络隐状态 $h_t$ 是网络内部记录电池历史信息的中间变量并随着输入的电池数据实时更新。传统使用GRU网络进行SOC估计时,隐状态需要每次进行初始化,从0进行大量网络迭代得到,本工作基于继承思想考虑当前时刻隐状态从前一时刻继承更新得到,从而避免大量的网络迭代过程。通过从前一时刻继承得到隐状态和当前时刻的电池信号数据结合,通过一次GRU网络计算即可得到当前时刻隐状态,并继而得到当前时刻SOC估计值,其计算公式见式(2)。改进后的GRU模型进行SOC估计的流程见图2。

$$\begin{cases} h_t = f_{\text{GRU}}(x_t, h_{t-1}) \\ \text{SOC}_t = f_{\text{DNN}}(h_t) \end{cases} \quad (2)$$

采用递推的GRU网络进行SOC估计,一个时刻的SOC估计仅需要经过一次GRU层的网络计算,并且隐状态 $h_t$ 可以存储更长时间的历史信息,而使SOC估计更加准确。由于GRU网络模型的计算量主要集中在GRU层的计算,因此改进方法的总体计算量大约是传统方法的 $1/m$ ,在文献[17], $m$ 的取值为1000,则能够实现改进方法的计算量降低99%以上,大大降低了BMS的计算和缓存压力。GRU网络的结构如图3,式(2)中 $h_t$ 的继承更新过程见式(3)。

$$h_{t-1} \rightarrow h_t: \begin{cases} r_t = \sigma(w_r \cdot [h_{t-1}, x_t] + b_r) \\ z_t = \sigma(w_z \cdot [h_{t-1}, x_t] + b_z) \\ h'_t = \tanh(w_h \cdot [r_t \circ h_{t-1}, x_t] + b_h) \\ h_t = (1 - z_t) \circ h_{t-1} + z_t \circ h'_t \end{cases} \quad (3)$$

式中, $r$ 和 $z$ 是网络的两个门控装置,用来控制历史信息对当前信息的影响程度; $w$ 和 $b$ 分别是网络内部的中间权重和偏置量,用来增加网络的非线性




图2 SOC实时估计框架

Fig. 2 SOC real-time estimation framework




图3 GRU网络结构图  
Fig. 3 GRU network structure

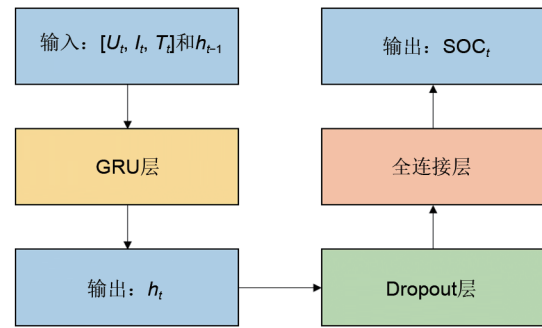


图4 递推GRU网络模型结构  
Fig. 4 Recursive GRU network model structure

拟合能力。整体的递推GRU网络模型见图4，为了防止神经网络过拟合，在网络模型中加入了Dropout层来提高网络的泛化能力。

### 1.2 迁移学习

GRU神经网络的离线训练需要大量的电池标签数据，而在很多应用场景中，电池标签数据获取不足，而大大限制了GRU神经网络方法估计电池SOC的可适用范围。针对这个问题，本工作利用迁移学习，考虑电池之间相似的性质，首先利用其他电池数据

进行初步训练得到GRU预训练网络模型，然后在预训练网络模型基础上，利用少量标签数据进行网络参数微调训练得到最终GRU网络模型。具体来说，在进行网络迁移训练时，为了提高迁移的效率，采用固定GRU层的网络参数不变，而只通过新的电池数据微调全连接层的网络参数的方式。采用迁移学习的方式，可以大幅度缩减网络训练所需要的时间和数据的需求量，有效拓宽GRU神经网络方法估计SOC的应用范围。迁移学习过程见图5。




图5 迁移学习过程  
Fig. 5 Transfer learning process

## 2 锂离子电池数据集

为了有效验证所提方法对于SOC实时估计的有效性，通过实验采集了三元镍钴锰电池在不同老化状态下的动态放电测试数据和Panasonic 18650三元锂离子电池公开数据集对网络进行测试。

### 2.1 实验数据集

以初始容量为20 Ah的镍钴锰三元锂离子电池作为实验对象，采用新威MGDW-408-40B环境试验箱提供恒温测试环境，采用新威CT-4002电池测试仪，其最大测试电流为400 A，实验环境见图6。

为了获取电池不同老化状态的动态放电数据，实验选择在40 °C环境下对电池进行循环老化实验，放电工况选择DST动态工况，充电采用1 C标准电流



图6 电池测试环境  
Fig. 6 Battery test environment

进行充电，每放电60个循环进行一次标准容量测试，实验共进行了300个放电循环，电池容量衰减为初始容量的80%。实验采集参数包括电压、电流、温

度、时间、功率、放电量、充放电效率等，采样频率为1 Hz，实验流程见图7。为了保证容量标定的准确性，采取1/3 C恒流恒压标准充电方式，并循环

3次计算放电量平均值作为电池容量标定值。其中Cycle0表示标定的循环次数，Cycle1表示动态放电的循环次数。

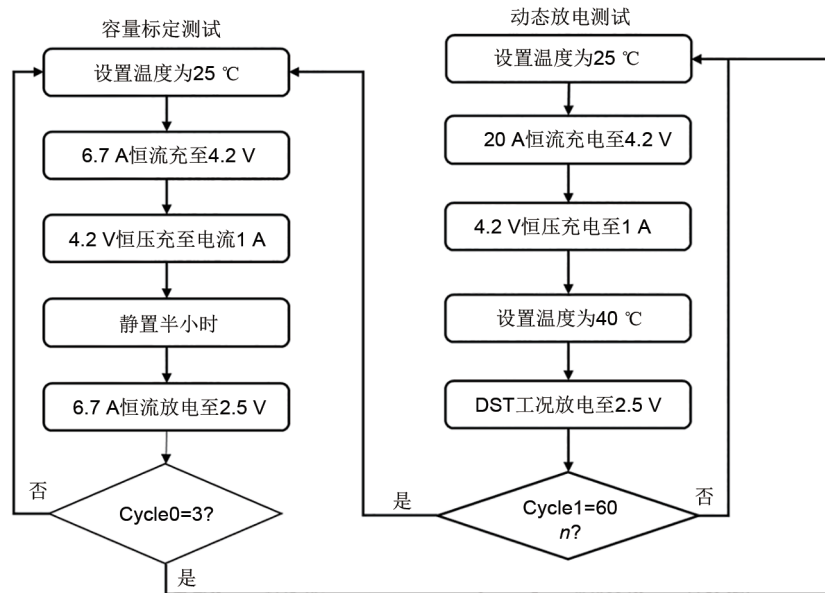


图7 电池测试流程

Fig. 7 Battery testing process

## 2.2 Panasonic 18650PF 锂离子电池数据集

Panasonic 18650PF 锂离子电池测试数据集是由加拿大马科斯特大学自动化所实验收集的公开数据集<sup>[30]</sup>。实验采用的是三元镍钴铝酸锂电池。实验分别在-20 °C、-10 °C、0 °C、10 °C和25 °C温度下对锂离子电池进行了9种工况的动态放电测试，包括HWFET、LA92、UDDS、US06四种标准工况以

及它们混合而成的Cycle1、Cycle2、Cycle3、Cycle4四种组合工况和由US06和LA92两种工况混合而成的NN工况。实验采集到的参数包括电压、电流、温度、时间、功率、放电量等，数据采样频率为10 Hz。本实验使用了其中的电压、电流、温度数据作为模型的输入来实时估计电池SOC。实验测试数据集和公开数据集的对比见表1。

表1 锂电池数据集对比

Table 1 Comparison of lithium battery data sets

数据集	电池类型	容量/Ah	老化状况	温度/ °C	数据规模	放电工况
实验测试数据集	镍钴锰	20	老化	40	小	DST工况
Panasonic 18650	镍钴铝	2.9	未老化	多种温度	大	多种工况

## 2.3 数据归一化

数据归一化(normalization)是将数据按照比例缩放至相同的区间，使神经网络在处理数据集时能够不受单位和量级的影响，从而提高神经网络的鲁棒性和收敛速度。本工作采用式(4)对数据进行归一化处理。

$$x_{\text{normal}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

其中， $x_{\text{normal}}$ 为归一化之后的数据； $x$ 为原始数

据； $x_{\max}$ 和 $x_{\min}$ 为原始数据中的最大值和最小值，归一化后的数据位于区间[0, 1]。

## 3 实验结果与分析

### 3.1 实验环境与网络参数设置

实验硬件包括CPU(6× Xeon E5-2678 v3)、GPU(NVIDIA GeForce RTX 2080 Ti 11GB)以及Windows操作系统，网络模型在pytorch环境中搭建。模型的相关参数设置见表2，参数的设置根据网络的特性

表 2 网络超参数设置

Table 2 Network super parameter setting

参数	设置
GRU 网络层数	1
GRU 隐藏层节点数目	500
Dropout 参数	0.2
优化函数	Adam
学习率	0.0001
Batch_size	72
损失函数	MSE
迭代次数	80

以及相关对比实验确定。

### 3.2 结果与分析

实验采用 Panasonic 18650PF 锂离子电池数据集中的 0 °C、10 °C、25 °C 的电池动态放电数据进行模型测试。为了验证模型的可靠性和泛化性能，实验采用 0 °C、10 °C、25 °C 下的 Cycle1、Cycle2、Cycle3、Cycle4 以及 NN 工况作为模型的训练集，把 0 °C、10 °C 和 25 °C 温度下的标准测试工况 HWFET 作为模型的验证集。图 8 是 HWFET 工况及 SOC 估计结果。

从图 8 SOC 估计结果可以看出，模型在不同温度下的 SOC 估计误差均保持在 2% 以内，说明所提方法对于温度有着良好的鲁棒性和泛化性能，在不同温度下均可以实现锂电池 SOC 的实时准确估计。同时，随着温度的降低，锂电池 SOC 的估计准确率略有下降，这主要是因为低温时锂电池内部物质活性降低，反应不完全，导致电池特性出现了一定的变化。除此之外，由于对 SOC 的实时递推估





图 8 不同温度下 HWFET 工况锂电池 SOC 估计结果  
(a) HWFET 工况；(b) 0 °C；(c) 10 °C；(d) 25 °C  
Fig. 8 SOC estimation results of lithium battery in HWFET at different temperatures (a) HWFET；(b) 0 °C；(c)10 °C；(d) 25 °C

计,保证了SOC估计的连续性,有效防止了不同时刻的SOC估计值出现跳变。

为了定量分析模型性能,采用平均误差(MAE)、最大误差(MAX)和均方根误差(RMSE)对SOC估计结果进行评估,采用文献[17]中使用GRU-RNN迭代获取隐状态的方式与本工作所提递推更新隐状态方法进行对比分析,其中迭代方法用于估计SOC的时间序列长度为1000,误差统计结果见表3,误差计算公式为

$$\begin{cases} \text{MAE} = \frac{1}{n} \sum_{t=1}^n |\text{SOC}_t - \text{SOC}'_t| \\ \text{MAX} = \max(|\text{SOC}_t - \text{SOC}'_t|) \\ \text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\text{SOC}_t - \text{SOC}'_t)^2} \end{cases} \quad (5)$$

表3 锂电池SOC估计结果

Table 3 SOC estimation results of lithium battery

温度/℃	工况	平均误差/%		最大误差/%		方均根误差/%		测试时间/s	
		迭代法 <sup>[17]</sup>	递推法	迭代法 <sup>[17]</sup>	递推法	迭代法 <sup>[17]</sup>	递推法	迭代法 <sup>[17]</sup>	递推法
0		1.6	0.79	2.61	2.21	1.76	1.05	1593	1.667
10	HWFET	0.62	0.59	2.25	1.71	0.79	0.69	1912	1.981
25		0.45	0.47	2.18	1.49	0.59	0.60	2078	2.122

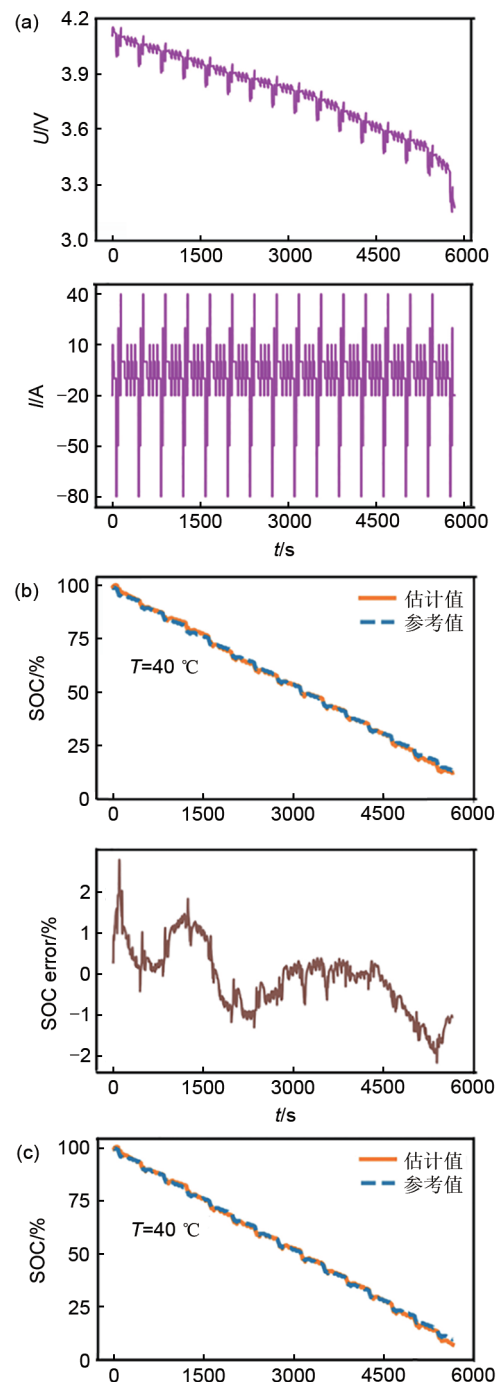
从误差统计结果可以看出,本工作所提出的基于递推GRU网络的锂电池SOC实时估计方法相比于传统迭代估计方法的估计误差略有降低,这主要是因为所提方法采用递推估计的方式,每一个时刻的SOC估计可以利用到电池之前所有时刻的放电信息。从估计用时来看,所提方法的测试时间只有传统迭代方法的一千分之一左右,这是因为迭代方法对于每一个时刻SOC的估计,需要在网络内迭代完整的时间序列长度,即1000次,而递推估计方法对于一个时刻SOC的估计,仅需经过一次网络计算。因此,相比于迭代方法,所提递推方法可以保证在不同温度下的SOC实时估计精度略下降的同时,计算复杂度大大降低,为其在BMS中实际应用提供了可能。同时,递推方法不需要缓存大量的电池历史放电数据,而仅需要当前时刻的电池信号数据,可以有效降低BMS的缓存成本。

### 3.3 迁移学习

为了测试迁移学习的有效性,将在Panasonic 18650PF锂离子电池数据集上训练得到的网络作为预训练网络模型,利用实验测试数据集中第60、120个周期的锂电池放电数据作为新的小规模数据

进行迁移学习得到新的网络模型参数,对电池第240个和第300个周期的放电过程进行SOC实时估计,DST工况及SOC估计结果如图9所示。

从图9可以看出,通过迁移学习得到的网络模型对电池第240和第300个周期的放电过程的SOC最大估计误差不超过3%。说明仅通过两个放电周期的标签数据进行迁移学习,就可以训练出良好的网络模型,实现不同种类电池在不同老化状态下的






图9 迁移学习模型在DST工况下不同老化状态的SOC估计结果(a)DST工况; (b)第240个周期; (c)第300个周期。

Fig. 9 SOC estimation results of different aging states of transfer learning model in DST (a)DST; (b)cycle240; (c)cycle300

SOC实时准确估计, 表明了迁移学习的有效性。面对部分应用场景中电池标签数据不足的情况, 通过迁移学习可以降低神经网络训练对于电池标签数据量的需求, 有效拓宽方法的可应用范围。

## 4 结 论

传统基于GRU神经网络的SOC估计方法存在计算复杂度过高的问题, 难以在实际BMS中实现SOC的实时估计。基于网络隐状态的时序继承与递推更新思想, 通过改进GRU网络的输出结构, 本工作提出了一种基于递推GRU神经网络的SOC实时估计方法, 其仅需对当前时刻电池采样数据进行一次网络计算, 便能实现当前时刻SOC的准确估计。该方法降低了99%以上的网络迭代计算量和BMS对电池历史数据的缓存需求。此外, 该方法在预训练网络模型的基础上, 可以利用迁移学习进行网络参数微调来应对各种电池训练数据不足的场景, 从而增加了方法的灵活性和适用范围。通过实验测试数据以及公开数据集的实验验证, 所提方法能够对不同型号的电池在不同老化状态和不同温度下的SOC进行准确实时估计, 最大估计误差不超过3%。本研究提高了GRU神经网络估计电池SOC的实用性, 为其未来在BMS中的实际应用提供了可能。

## 参 考 文 献

[1] LU L G, HAN X B, LI J Q, et al. A review on the key issues for lithium-ion battery management in electric vehicles[J]. Journal of Power Sources, 2013, 226: 272-288.  
 [2] ZHANG C P, WANG L Y, LI X, et al. Robust and adaptive estimation of state of charge for lithium-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2015, 62(8): 4948-4957.

[3] 武龙星, 庞辉, 晋佳敏, 等. 基于电化学模型的锂离子电池荷电状态估计方法综述[J]. 电工技术学报, 2022, 37(7): 1703-1725.  
 WU L X, PANG H, JIN J M, et al. A review of SOC estimation methods for lithium-ion batteries based on electrochemical model[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1703-1725.  
 [4] 巫春玲, 胡雯博, 孟锦豪, 等. 基于最大相关熵扩展卡尔曼滤波算法的锂离子电池荷电状态估计[J]. 电工技术学报, 2021, 36(24): 5165-5175.  
 WU C L, HU W B, MENG J H, et al. State of charge estimation of lithium-ion batteries based on maximum correlation-entropy criterion extended Kalman filtering algorithm[J]. Transactions of China Electrotechnical Society, 2021, 36(24): 5165-5175.  
 [5] XU Z C, WANG J, LUND P D, et al. Co-estimating the state of charge and health of lithium batteries through combining a minimalist electrochemical model and an equivalent circuit model[J]. Energy, 2022, 240: doi: 10.1016/j.energy.2021.122815.  
 [6] HE H W, XIONG R, FAN J X. Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach[J]. Energies, 2011, 4(4): 582-598.  
 [7] HU X S, LI S B, PENG H E. A comparative study of equivalent circuit models for Li-ion batteries[J]. Journal of Power Sources, 2012, 198: 359-367.  
 [8] 朱奕楠, 吕桃林, 赵芝芸, 等. 基于并行卡尔曼滤波器的锂离子电池荷电状态估计[J]. 储能科学与技术, 2021, 10(6): 2352-2362.  
 ZHU Y N, LÜ T L, ZHAO Z Y, et al. State of charge estimation of lithium ion battery based on parallel Kalman filter[J]. Energy Storage Science and Technology, 2021, 10(6): 2352-2362.  
 [9] YAN W Z, ZHANG B, ZHAO G Q, et al. A battery management system with a lebesgue-sampling-based extended Kalman filter[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3227-3236.  
 [10] SHEHAB EL DIN M, HUSSEIN A A, ABDEL-HAFEZ M F. Improved battery SOC estimation accuracy using a modified UKF with an adaptive cell model under real EV operating conditions[J]. IEEE Transactions on Transportation Electrification, 2018, 4(2): 408-417.  
 [11] SUN F C, HU X S, ZOU Y, et al. Adaptive unscented Kalman filtering for state of charge estimation of a lithium-ion battery for electric vehicles[J]. Energy, 2011, 36(5): 3531-3540.  
 [12] DAI H F, WEI X Z, SUN Z C, et al. Online cell SOC estimation of Li-ion battery packs using a dual time-scale Kalman filtering for EV applications[J]. Applied Energy, 2012, 95: 227-237.  
 [13] SHEN H R, ZHOU X Y, WANG Z J, et al. State of charge estimation for lithium-ion battery using Transformer with immersion and invariance adaptive observer[J]. Journal of Energy Storage, 2022, 45: doi: 10.1016/j.est.2021.103768.  
 [14] WEI Z B, MENG S J, XIONG B Y, et al. Enhanced online model identification and state of charge estimation for lithium-ion battery with a FBCRLS based observer[J]. Applied Energy, 2016, 181: 332-341.  
 [15] CHEN N, ZHANG P, DAI J Y, et al. Estimating the state-of-charge of lithium-ion battery using an H-infinity observer based on electrochemical impedance model[J]. IEEE Access, 2020, 8: 26872-26884.

- [16] TIAN J P, XIONG R, SHEN W X, et al. State-of-charge estimation of LiFePO<sub>4</sub> batteries in electric vehicles: A deep-learning enabled approach[J]. *Applied Energy*, 2021, 291: doi: 10.1016/j.apenergy.2021.116812.
- [17] 李超然, 肖飞, 樊亚翔, 等. 基于门控循环单元神经网络和Huber-M估计鲁棒卡尔曼滤波融合方法的锂离子电池荷电状态估算方法[J]. *电工技术学报*, 2020, 35(9): 2051-2062.
- LI C R, XIAO F, FAN Y X, et al. A hybrid approach to lithium-ion battery SOC estimation based on recurrent neural network with gated recurrent unit and Huber-M robust Kalman filter[J]. *Transactions of China Electrotechnical Society*, 2020, 35(9): 2051-2062.
- [18] CALIWAG A, LIM W. Optimal least square vector autoregressive moving average for battery state of charge estimation and forecasting[J]. *ICT Express*, 2021, 7(4): 493-496.
- [19] LI R, XU S H, LI S B, et al. State of charge prediction algorithm of lithium-ion battery based on PSO-SVR cross validation[J]. *IEEE Access*, 2020, 8: 10234-10242.
- [20] SALKIND A J, FENNIE C, SINGH P, et al. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology[J]. *Journal of Power Sources*, 1999, 80(1/2): 293-300.
- [21] DENG Z W, HU X S, LIN X K, et al. Data-driven state of charge estimation for lithium-ion battery packs based on Gaussian process regression[J]. *Energy*, 2020, 205: doi: 10.1016/j.energy.2020.118000.
- [22] LI J, ZIEHM W, KIMBALL J, et al. Physical-based training data collection approach for data-driven lithium-ion battery state-of-charge prediction[J]. *Energy and AI*, 2021, 5: doi: 10.1016/j.egyai.2021.100094.
- [23] ZHAO X B, XUAN D J, ZHAO K Y, et al. Elman neural network using ant colony optimization algorithm for estimating of state of charge of lithium-ion battery[J]. *Journal of Energy Storage*, 2020, 32: doi: 10.1016/j.est.2020.101789.
- [24] CHEN J X, FENG X, JIANG L, et al. State of charge estimation of lithium-ion battery using denoising autoencoder and gated recurrent unit recurrent neural network[J]. *Energy*, 2021, 227: doi: 10.1016/j.energy.2021.120451.
- [25] MA L, HU C, CHENG F. State of charge and state of energy estimation for lithium-ion batteries based on a long short-term memory neural network[J]. *Journal of Energy Storage*, 2021, 37: doi: 10.1016/j.est.2021.102440.
- [26] DENG Z W, YANG L, CAI Y S, et al. Online available capacity prediction and state of charge estimation based on advanced data-driven algorithms for lithium iron phosphate battery[J]. *Energy*, 2016, 112: 469-480.
- [27] 李嘉波, 魏孟, 叶敏, 等. 基于高斯过程回归的锂离子电池SOC估计[J]. *储能科学与技术*, 2020, 9(1): 131-137.
- LI J B, WEI M, YE M, et al. SOC estimation of lithium-ion batteries based on Gauss process regression[J]. *Energy Storage Science and Technology*, 2020, 9(1): 131-137.
- [28] YANG F F, LI W H, LI C, et al. State-of-charge estimation of lithium-ion batteries based on gated recurrent neural network[J]. *Energy*, 2019, 175: 66-75.
- [29] 朱元富, 贺文武, 李建兴, 等. 基于Bi-LSTM/Bi-GRU循环神经网络的锂电池SOC估计[J]. *储能科学与技术*, 2021, 10(3): 1163-1176.
- ZHU Y F, HE W W, LI J X, et al. SOC estimation for Li-ion batteries based on Bi-LSTM and Bi-GRU[J]. *Energy Storage Science and Technology*, 2021, 10(3): 1163-1176.
- [30] CHEMALI E, KOLLMEYER P J, PREINDL M, et al. State-of-charge estimation of Li-ion batteries using deep neural networks: A machine learning approach[J]. *Journal of Power Sources*, 2018, 400: 242-255.