

DOI: 10.13382/j.jemi.B2508236

基于改进领域自适应迁移学习的锂电池 SOH 估计*

郭向伟^{1,2} 袁江龙¹ 陈岗¹ 王晨¹ 苏佳文¹

(1. 河南理工大学电气工程与自动化学院 焦作 454003; 2. 河南省煤矿装备智能检测与控制重点实验室 焦作 454003)

摘要: 精确的健康状态 (state of health, SOH) 对于锂电池储能系统安全运行意义重大。针对目前 SOH 估计方法适用性差、计算量大且精度低的不足, 提出一种基于改进领域自适应迁移学习的锂电池 SOH 估计方法。首先, 设计一种基于等充电电压差时间间隔的新型 SOH 特征参数, 以模拟随机恒流充电片段, 简化 SOH 估计模型的输入参数; 其次, 通过引入自适应迁移学习, 结合门控循环单元 (GRU) 网络特性, 提出一种基于改进领域自适应迁移学习的 GRU 网络结构, 以减少负迁移并降低网络训练负荷; 再次, 基于新型健康特征及神经网络, 实现基于改进领域自适应迁移学习的 SOH 估计; 最后, 基于自主实验平台测试数据, 对所提估计方法进行验证。结果表明, 所提估计方法相比于基于传统领域自适应迁移学习的方法, 测试倍率为 0.75 C 时, 平均绝对误差和均方根误差分别降低了 3.0% 和 3.8%; 测试倍率为 0.5 C 时, 降低了 5.8% 和 4.3%。和基于微调迁移学习的估计方法相比, 测试倍率 0.75 C 时, 两种误差分别降低了 22.9% 和 17.4%; 测试倍率为 0.5 C 时, 分别降低了 25.8% 和 14.7%。

关键词: 锂电池; 健康状态; 等充电电压差; 迁移学习

中图分类号: TN711; TM912 **文献标识码:** A **国家标准学科分类代码:** 470.40

SOH estimation for lithium batteries based on improved domain adaptive transfer learning

Guo Xiangwei^{1,2} Yuan Jianglong¹ Chen Gang¹ Wang Chen¹ Su Jiawen¹

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China;

2. Henan Key Laboratory of Intelligent Detection and Control of Coal Mine Equipment, Jiaozuo 454003, China)

Abstract: Accurate state of health (SOH) is of great significance for safe operation of Li-ion battery storage systems. Aiming at the shortcomings of the current SOH estimation methods in terms of poor applicability, large computational load and low accuracy, a SOH estimation method for lithium batteries based on improved domain adaptive transfer learning is proposed. First, a new SOH indicator based on time interval for equal charging voltage difference is designed, which can simulate the random constant current charging segments and simplify the input parameters of the SOH estimation model. Second, by introducing adaptive transfer learning and combining the GRU network characteristics, a GRU network based on an improved domain adaptive transfer learning is proposed to reduce the negative transfer and network training load. Again, based on the new SOH indicator and neural network, the SOH estimation is realized. Finally, the proposed estimation method is validated based on the test data of the self-built experimental platform. The verification results show that, compared with the method based on traditional domain adaptive transfer learning, the mean absolute error and root mean square error of the proposed method are reduced by 3.0% and 3.8% respectively when the test current is 0.75 C. A reduction of 5.8% and 4.3% was achieved at a test current of 0.5 C. Compared with the estimation method based on fine-tuned transfer learning, the error is reduced by 22.9% and 17.4% respectively when the test rate is 0.75 C. At a test current of 0.5 C, the reductions are 25.8% and 14.7%, respectively.

Keywords: lithium battery; state of health; equal charging voltage difference; transfer learning

收稿日期: 2025-03-15 Received Date: 2025-03-15

* 基金项目: 国家自然科学基金(62373137)、河南省重点研发专项(241111241700)、河南省科技攻关(252102240008)、河南理工大学青年骨干教师(2023XQG-04)项目资助

0 引言

锂电池凭借其能量密度高、使用寿命长等优点已广泛应用于电池储能系统^[1]。锂电池的老化可能导致整个储能系统的故障、失效,甚至引发重大安全事故。锂电池的老化是多种因素耦合的结果,无法直接测量,只能进行估计。健康状态(state of health, SOH)作为表征锂电池老化的重要指标,准确的 SOH 估计对于锂电池最佳性能的发挥和系统安全具有重大意义。

锂电池 SOH 通常定义为当前最大可用容量与额定容量的比值。常见的 SOH 估计方法^[2-3]包括直接测量法、基于模型的方法和数据驱动法。其中,数据驱动法可以在不依赖电池内部复杂机理的前提下描述电池的退化行为,受到越来越多的关注。本文针对基于数据驱动的 SOH 估计方法进行研究。

数据驱动法设计的关键在于 SOH 特征参数的提取和神经网络结构的合理设计。文献[4-5]基于容量增量和单位时间内的电压变化设计健康特征,这些方法虽然整体流程易于实现,但仅适合在恒流放电场景下使用,而实际电池放电过程中的电流变化具有高度不确定性,导致其应用受到较大限制。文献[6]基于固定步长最小二乘支持向量机和遗传算法建立了 SOH 估计框架,在其设定的电压范围内,估计精度小于 2%,若实际充电电压不在其设定范围,估计精度显著下降。文献[7]同样从局部充电曲线提取健康特征,通过建立一种非线性自回归循环神经网络进行 SOH 估计,其以大规模的数据集换取高精度的估计结果,不利于神经网络计算负荷的降低。文献[8]基于容量曲线和放电电压曲线设计健康特征,文献[9]基于充电电压曲线和容量增量曲线设计健康特征。虽然这些方法取得了较为理想的估计结果,但由于引入了较多的变量,使得神经网络的计算负荷显著增加,并且部分健康特征并不是所有工况下都能良好表征 SOH。文献[10]基于历史数据对当前 SOH 进行估计,虽然取得了较为理想的估计精度,但其假设历史数据已知,一方面 SOH 是一个长时间尺度的状态量,大量的历史数据不利于计算负荷的降低;另一方面质量较差的数据随着时间更新而不断向后传递,导致预测模型鲁棒性及实时性较差。文献[11]通过研究不同健康特征和 SOH 的相关性,证明了恒流充电时间与 SOH 具有可靠的映射关系,简化了健康特征获取过程,实验结果估计误差小于 1.2%。文献[12]同样以不同电流倍率的局部充电曲线建立健康特征以估计 SOH,虽然扩展了方法的适用范围,但其要求荷电状态必须在 20%~70%,且所使用的电流倍率较小,和实际应用存在偏差。

神经网络结构的设计以提高估计精度、降低网络训

练负荷、扩展网络适用性为目标。文献[13-14]基于自适应遗传算法和 BP(back propagation)神经网络进行 SOH 估计,上述方法虽然不同程度地提高了估计精度,但并没有克服 BP 网络收敛速度慢、训练时间长的不足。文献[15]基于径向基函数(radial basis function, RBF)神经网络进行状态估计,网络收敛速度显著提高,但其核心参数设置尚无明确的理论支撑,调参过程繁琐且最优参数极易波动。文献[16]通过改进元学习策略,提出一种基于并行 CNN-Attention 模型的元学习方法,实现了基于小样本数据的 SOH 估计,但其依靠不同网络组合的方式建立模型,使得模型参数设计复杂且泛化能力差。文献[17]首先基于迁移学习消除了 SOH 特征参数之间的冗余信息,其次将深度信念神经网络(deep belief network, DBN)和长短期记忆(long short-term memory, LSTM)神经网络结合,用以强化神经网络的特征提取能力,该方法取得了理想的估计精度,但 DBN 训练时间过长,不利于 SOH 的实时估计。文献[18]基于多层卷积神经网络,结合迁移学习进行 SOH 估计。文献[19]设计了基于自注意力的深度迁移学习算法用于实现 SOH 的高精度、强鲁棒估计。文献[20]则基于迁移学习设计了一种新型回归对抗性网络实现 SOH 的估计。上述方法中迁移学习的应用不同程度的降低了模型的运算量和收敛时间,但由迁移学习引入的负迁移对估计精度和模型运算量造成了不利影响。基于以上分析,目前利用数据驱动实现 SOH 估计的方法主要存在如下不足。

1) 较多方法基于完整的恒流充电曲线或固定电压范围的充电曲线获取健康特征^[11-12,18],而电池实际工作中,工况具有很强的随机性,完整的充电曲线或固定范围的充电曲线不易获取。

2) 上述估计方法数据量较大且网络结构复杂,需要消耗大量的计算资源^[13-14,16],尤其是基于深度学习的算法,将上述方法迁移到面向嵌入式的电池管理系统中比较困难,寻求精度高且计算代价小的 SOH 估计方法是基于数据驱动 SOH 估计的研究目标。

结合以上分析,本文提出一种基于改进领域自适应迁移学习的锂电池 SOH 估计方法。首先,设计新型健康特征,简化网络模型输入。其次,基于 GRU 神经网络,通过设计一种新型自适应迁移学习算法,降低网络训练负荷。提出一种基于等充电电压差时间间隔(time interval for equal charging voltage difference, TI-ECVD)的健康特征,使得网络模型的输入可以为任意恒流充电片段的电流及起始电压,这种设计不仅简化了输入条件,同时由于电压和电流可以直接测量,参数获取更为便捷。基于门控循环单元(GRU)网络参数少、收敛快的特点,以 GRU 网络为基础,通过引入双曲正切函数,提出一种改进领域自适应迁移学习(improved domain adaptive transfer learning,

IDATL)算法,使目标域和源域的差异自适应减小,避免负迁移的同时降低网络训练负荷,实现高精度、低计算量的 SOH 估计。

1 特征参数设计

基于不同 SOH 条件下的恒流充电曲线设计健康特征。

1.1 恒流充电曲线

为精确估计 SOH,需要对电池循环数据进行分析,以提取理想的健康特征。本文实验采用的锂电池参数如表 1 所示。基于自主搭建的实验平台采集不同 SOH 条件下的恒流充电曲线,自主实验平台如图 1 所示。实验平台由安装有控制软件的上位机、中位机、Neware 可编程电子负载和温箱组成。电子负载型号为 CT-4008T-5V6A-S1,测试误差 $<0.05\%$,温箱误差 $\pm 0.5\text{ }^{\circ}\text{C}$ 。

表 1 电池参数

Table 1 Battery parameters

参数	数值
型号	日本松下 NCR18650BD
充/放电截止电压	4.2 V/2.7 V
标称电压/容量/内阻	3.7 V/3.2 Ah/22 m Ω



图 1 测试平台

Fig. 1 Test platform

本文在 $25\text{ }^{\circ}\text{C}$ 环境下进行循环老化实验。恒流倍率分别为 0.2、0.5、0.75 和 1 C,涵盖了锂电池常见工况的电流范围。每一组循环测试包括恒流充电数据获取和加速电池老化^[9]。

1) 恒流充电数据

(1) 对电池进行恒流(3.2 A,即 1 C)恒压(4.2 V)充电和恒流(1 C)恒压(2.7 V)放电,充放电截止电流设置为 0.032 A(0.01 C);充放电转换过程,电池静置 1 h 以消除极化效应。

(2) 依次改变充电倍率为 0.75、0.5 和 0.2 C 重复执

行步骤(1)。

2) 加速老化

(1) 以 5 A 电流对电池进行恒流恒压(4.2 V)充电和恒流恒压(2.7 V)放电,充放电截止电流设置为 0.032 A(0.01 C);充放电转换过程,电池静置 1 小时以消除极化效应。

(2) 重复执行步骤(1)3 次。

本文实验过程将 SOH 定义为一次充放电循环中的充电容量、放电容量的平均值与电池出厂时最大可用容量的比值,其计算公式为:

$$SOH = \frac{C_c + C_d}{2C_n} \quad (1)$$

式中: C_c 和 C_d 分别为充电容量和放电容量; C_n 为电池出厂时额定容量。实验过程持续 3 个月,电池最大可用容量随着循环次数的增加逐渐减小。选取 SOH 范围为 $[0.88, 0.96]$,在该区间内验证新型估计方法。此范围下以 SOH 近似间隔 0.01 对恒流充电曲线进行选取从而得到不同 SOH 条件下的健康特征,以 1 C 恒流充电倍率为例,9 条恒流充电曲线如图 2 所示。

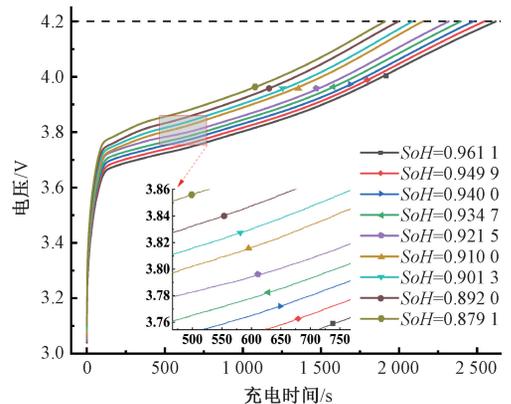


图 2 1 C 倍率下不同 SOH 的恒流充电曲线

Fig. 2 Charging curves for different SOHs at 1 C

1.2 健康特征

恒流充电数据包含不同倍率条件下、不同电压值分别对应的相对充电时刻。取 SOH 为 0.96、0.94、0.92、0.90 和 0.88 时的恒流充电数据进行模型标定,以各个倍率恒流充电数据建立健康特征,对应的数据集如表 2 所示。当电池充电时,即使充电开始前电池电压为下限截止电压 2.7 V,由于极化效应,充电开始时,当充电倍率为 0.2 C 时,其电压瞬间跳变到 3 V 左右,当充电倍率为 1 C 时,其电压瞬间跳变到 3.4 V 左右。本文将电池充电过程端电压为 2.9 V 的时刻定义为零时刻。另外,由于目前可靠的电压采样电路测量精度多为 10 mV 数量级,本文以 10 mV 为单位建立健康特征数据集。将锂电池电压在 2.9~4.2 V 以 10 mV 为单位等分,共 131 个电压标签。

表 2 不同 SOH 条件下数据集
Table 2 Data of different SOHs

电压/V	不同倍率对应的时刻			
	0.2 C	0.5 C	0.75 C	1 C
2.90	0	0	0	0
2.91	t1_1	t2_1	t3_1	t4_1
2.92	t1_2	t2_2	t3_2	t4_2
...
4.20	t1_130	t2_130	t3_130	t4_130

为探究新型老化特征和目前常见老化特征与 SOH 的相关程度。基于 0.2、0.5 C 倍率获取完整的充放电曲线。选择 0.2 和 0.5 C 倍率的原因在于电流越小,不同 SOH 对应的充电曲线差异越小,若 0.2 或 0.5 C 倍率时健康特征与 SOH 具有理想的相关性,则更大倍率时,充电曲线差异更大,理论上健康特征与 SOH 的相关性更高。提取常见的恒流充电时间(constant current charging time, CCCT)、恒流放电时间(constant current discharge time, CCDT)和本文所设计的健康特征进行对比分析。

为量化健康特征与 SOH 的相关性,以皮尔逊相关系数作为衡量指标^[11]。在 0.2 和 0.5 C 充电倍率条件下,共计 18 条老化曲线中获取健康特征,分析不同特征与 SOH 的相关程度,所选老化曲线的 SOH 覆盖了老化实验的健康周期。其中,TI-ECVD 把充电电压在 3.50~3.70 V 区间所对应的时间间隔作为参考。3.50~3.70 V 为电池充放电平台期,电压变化较为平缓且范围较小,如果该范围表征 SOH 较为理想,则其余电压区间理论上表征 SOH 效果更好。针对每个特征参数 X , 给定特征序列 $X = \{X_1, X_2, X_3, \dots, X_n\}$ 和健康状态序列 $SOH = \{SOH_1, SOH_2, SOH_3, \dots, SOH_n\}$, 其相关性计算公式为:

$$\rho_{X,Y} = \frac{\text{cov}(X, SOH)}{\sigma_X \sigma_Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(SOH_i - \overline{SOH})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (SOH_i - \overline{SOH})^2}} \quad (2)$$

式中: X 表示电池的特征值; n 为特征序列和 SOH 序列的长度; \bar{X} 和 \overline{SOH} 分别为特征序列和 SOH 序列的平均值; $\text{cov}(X, SOH)$ 表示特征和 SOH 之间的协方差; σ_X 和 σ_Y 分别表示特征序列和 SOH 序列的标准差。计算得每个特征和 SOH 的皮尔逊系数如表 3 所示。皮尔逊系数越接近 1, 相关性越高。

表 3 不同健康特征与 SOH 的皮尔逊相关系数
Table 3 Pearson correlation coefficient for different health indicators and SOH

参数	0.2 C	0.5 C
CCCT	0.984 5	0.979 8
CCDT	0.864 8	0.830 1
TI-ECVD	0.992 9	0.987 7

由表 3 可知, TI-ECVD、CCCT 和 SOH 的相关性较高。对于 CCCT, 在电池实际充电过程中, 由于充电开始时电池内含有剩余电量, 并且可能在未达到截止电压时充电停止, 使得在多数工况条件下难以准确获取恒流充电时间。本文等充电电压差时间间隔可以在不同局部电压区间灵活提取, 对复杂环境的适用性更强。表 3 表明本文所设计的等充电电压差时间间隔相比于其他常见特征参数, 与 SOH 具有更高的相关性。

2 基于 IDATL 的 GRU 网络设计

特征参数是基于神经网络状态估计的基础, 而稳定、高效的网络结构是基于神经网络 SOH 估计的关键。首先基于传统领域自适应迁移学习(traditional domain adaptive transfer learning, TDATL)算法建立 IDATL 算法, 以降低神经网络训练负荷, 其次设计基于 IDATL 的 GRU 神经网络, 用以实现 SOH 的高精度、低运算量估计。

2.1 IDATL 算法

如何克服源域和目标域特征分布差异所带来的迁移阻碍是迁移学习研究的关键^[18,21-22]。领域自适应是迁移学习网络(transfer learning network, TLN)中重要的部分, 在迁移学习过程中, 通过调整最大平均差异项(maximum mean discrepancy, MMD)可以使目标域拥有与源域相似的特征分布。MMD 是一种非参数距离度量指标, 用于度量源域和目标域之间的数据分布差异^[21-22]。

假设存在源域 D_S 和目标域 D_T , 如式(3)所示。

$$\begin{cases} D_S = [(x_1^s, y_1^s), \dots, (x_j^s, y_j^s)] \\ D_T = [(x_1^t, y_1^t), \dots, (x_k^t, y_k^t)] \end{cases} \quad (3)$$

若源域输入 X^S 和目标域输入 X^T 服从不同的分布, 则 MMD 的定义^[21-22]如式(4)、(5)所示。

$$\begin{cases} X^S = [x_1^s, \dots, x_j^s] \\ X^T = [x_1^t, \dots, x_k^t] \end{cases} \quad (4)$$

$$\text{MMD}_{\mathcal{H}}(X^S, X^T) = \left\| \frac{1}{j} \sum_{i=1}^j \varphi(x_i^s) - \frac{1}{k} \sum_{i=1}^k \varphi(x_i^t) \right\|_{\mathcal{H}}^2 \quad (5)$$

式中: j 和 k 分别为源域和目标域的序列长度; $\|\cdot\|_{\mathcal{H}}^2$ 表示再生核希尔伯特空间(reproducing kernel Hilbert space, RKHS)中的二范数运算; φ 是 RKHS 中的一个映射函数。MMD 越小, TLN 中两个数据分布之间的特征相关性越强。通过引入 MMD, 机器学习可以自适应地学习源域和目标域中的数据, 生成映射函数, 无需在 RKHS 中手动设置内核。TLN 损失函数为:

$$\text{Loss} = \text{MSE}(\mathbf{h}_t) + \lambda \cdot \text{MMD}(\mathbf{h}_s, \mathbf{h}_t) \quad (6)$$

式中: Loss 与 $\text{MSE}(\mathbf{h}_t)$ 分别表示 TLN 的总损失和目标模型的均方误差损失; \mathbf{h}_s 和 \mathbf{h}_t 分别为源域和目标域的特征

信息; $\lambda \cdot \text{MMD}(\mathbf{h}_s, \mathbf{h}_t)$ 表示 TLN 的自适应损失, 反映了源域和目标域的域分布差异; λ 为权衡 MMD 和自适应损失的非负自适应正则化参数, 控制 TLN 的迁移深度。随着 TLN 迭代次数增加, 源域和目标域的差异逐渐减小, 此时固定的 λ 会使模型依然保持较高的迁移深度, 但增大了负迁移的可能性。负迁移表现为模型的收敛时间增加或阻碍模型学习的顺利进行以及知识的正确掌握。

为克服传统 TLN 训练后期存在的负迁移问题, 本文提出一种改进领域自适应迁移学习算法, 针对源域与目标域之间的 MMD 距离做出改进, 使迁移深度随着 MMD 的减小逐渐降低。改进 MMD 及其对应的模型损失函数如式(7)和(8)所示。

$$\text{IMMD}(\mathbf{h}_s, \mathbf{h}_t) = \frac{\text{MMD}(\mathbf{h}_s, \mathbf{h}_t)}{\tanh[m - \text{MMD}(\mathbf{h}_s, \mathbf{h}_t)]} \quad (7)$$

$$\text{Loss}_{\text{total}} = \text{MSE}(\mathbf{h}_t) + \lambda \cdot \text{IMMD}(\mathbf{h}_s, \mathbf{h}_t) \quad (8)$$

在最大均值差异的基础上, 设计同样包含 MMD 项的双曲正切项为分母。式(7)中, 通过双曲正切函数使分母保持在区间 $[0, 1]$, 分母项随着 MMD 降低逐渐增加, 使得迁移深度随迭代次数增加而逐渐降低。 m 为不小于 MMD 的非负阈值参数, 控制迁移深度降低的速度, 迁移深度降低过快会延长模型的收敛时间; 过快则会造成从源域共享至目标域过多无用的参数, 导致负迁移的出现。式(8)中, $\text{Loss}_{\text{total}}$ 为模型损失; λ 和分母 $\tanh[m - \text{MMD}(\mathbf{h}_s, \mathbf{h}_t)]$ 控制每次迭代迁移深度, 从源域迁移至目标域知识越多, 则意味着迁移深度越大。基于传统 MMD 和改进 MMD 的自适应迁移学习效果对比如图 3 所示。

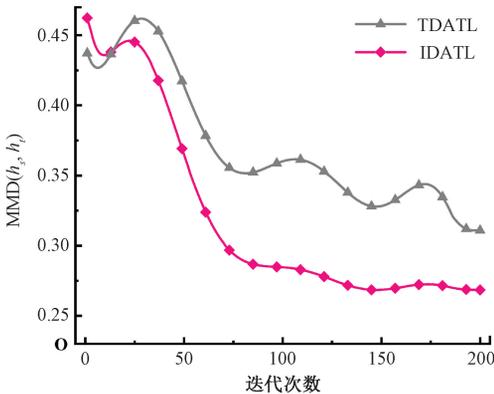


图 3 不同模型 MMD 变化过程

Fig. 3 Changes in MMD of different models

由图 3 可知, 改进的自适应迁移学习相比于传统迁移学习, 在相同迭代周期内, 可以更大程度地降低源域和目标域的差异。这是由于本文提出的改进领域自适应方法可以根据模型训练状态自发地降低迁移深度, 从而减少负迁移出现的次数并缩短总体迁移学习的收敛时间。

2.2 基于 IDATL 的 GRU 网络设计

GRU 作为循环神经网络的变体, 可以有效克服反向传播中的梯度问题^[23]。本文以 GRU 网络为基础构建基于 IDATL 的神经网络, 其结构如图 4 所示。一方面, 在 GRU 层采用基于微调策略的迁移思想, 将源域模型训练好的参数迁移至待训练的目标域模型, 使目标域模型的 GRU 层继续训练参数以快速达到收敛。另一方面, 在全连接层应用 IDATL, 降低模型训练负荷并避免负迁移。通过 GRU 层的参数共享以及全连接层的领域自适应, 源域与目标域的特征从低维空间上移至高维空间, 最大程度地降低了两个域分布的差异。

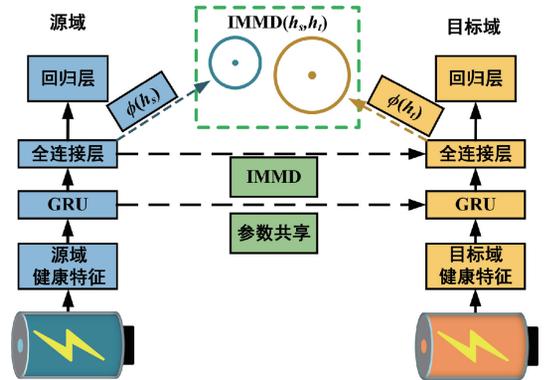


图 4 基于 IDATL 的 GRU 网络结构

Fig. 4 GRU network based on IDATL

3 基于改进领域自适应迁移学习的 SOH 估计

基于健康特征建立 5 个不同 SOH 条件下、4 个不同充电速率条件下电压值和相对时刻的数据集, 以基于 IDATL 的 GRU 网络为基础建立估计模型。估计过程如图 5 所示。在线预测阶段, 将任意恒流充电片段电流倍率、起始电压 (started voltage, SV) 和结束电压 (end voltage, EV) 输入模型, 输出不同 SOH 条件下模型预测的时刻值。求解 5 个标定模型输出的时间差, 将 5 个时间差和实测时间差比较, 通过二分法估计实测时间差对应的 SOH。

1) 5 个时间差中大于实际时间差最少的时间差记为 T_R , 小于实际时间差最少的时间差记为 T_F , 实测时间差为 T_A ; 将 T_R 、 T_F 两个时间差所对应的 SOH 求差, 将实测时间差 T_A 和 T_F 做差。

2) 通过二分法计算实测时间差对应的 SOH。

$$\text{SOH}_A = \text{SOH}_F + \frac{T_A - T_F}{T_R - T_F} (\text{SOH}_R - \text{SOH}_F) \quad (9)$$

至此, 基于改进领域自适应迁移学习的锂电池 SOH 估计方法设计完成。

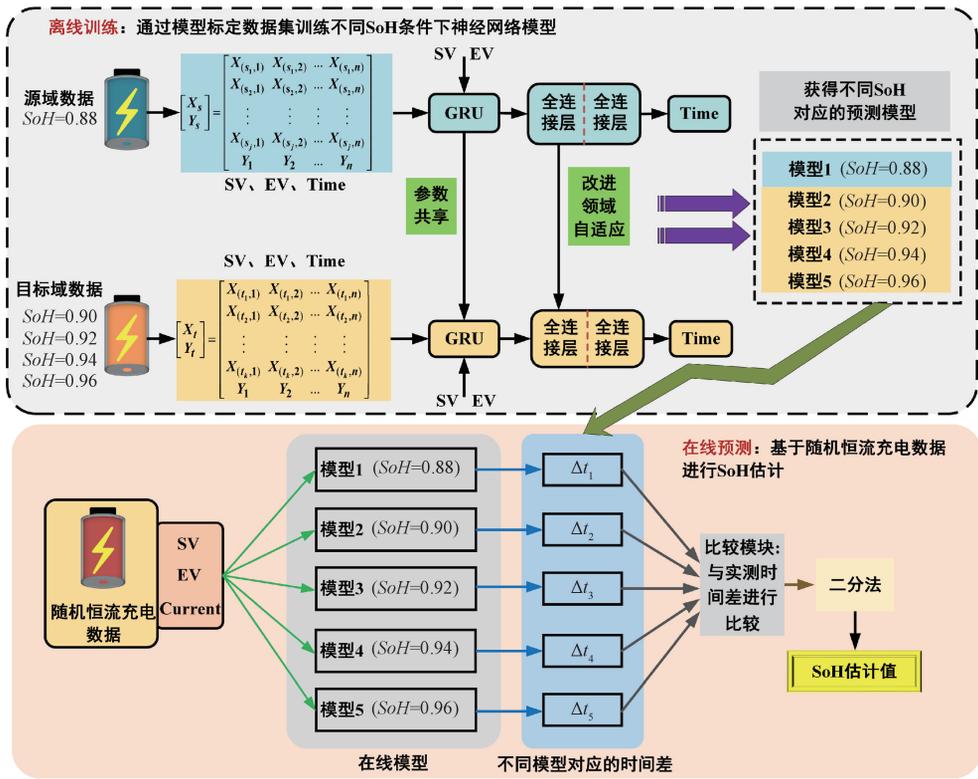


图 5 基于改进领域自适应迁移学习的 SOH 估计

Fig. 5 SOH estimation based on improved domain adaptive transfer learning

4 预测性能分析

采用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 对 SOH 估计模型的预测性能进行评估^[22,24]。基于 MATLAB (2023a) 建立验证模型, 与其他估计方法进行精度和速度的对比分析。

4.1 与主流 SOH 估计方法对比

将基于 IDATL 的 GRU 网络与 LSTM 网络、GRU 网络、基于改进萤火虫算法 (improved firefly algorithm, IFA) 优化的粒子滤波器 (particle filter, PF)^[25] 和基于麻雀搜索算法 (sparrow search algorithm, SSA) 优化的 BP 神经网络^[26] 进行预测能力对比。对比过程如图 6 所示。

对比模型中, 基于二分法对模型参数进行调试, 确定最优模型参数。两个 GRU 和 LSTM 的神经元数目均为 15, 全连接层 I 和全连接层 II 的神经元数目分别为 10 和 1; 非负自适应正则化参数 λ 为 5, 非负阈值参数 m 为 0.5; 粒子滤波器的粒子数为 80; 麻雀算法中, 进化次数为 50, 种群规模为 20。分别选用 0.75 C 和 0.5 C 恒流充电数据分别作为测试集, 训练集为与测试集对应的剩余 3 个倍率。预测结果如图 7 和表 4 所示。

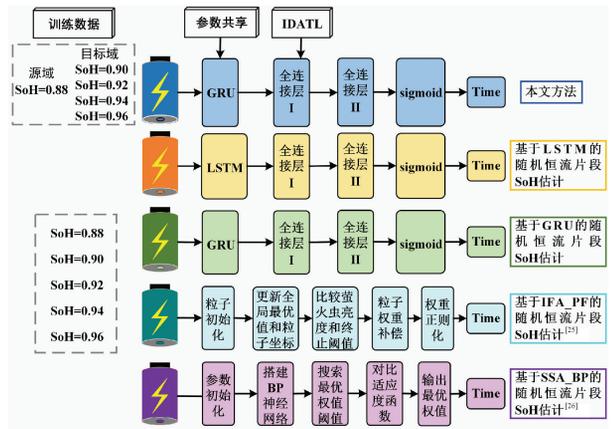
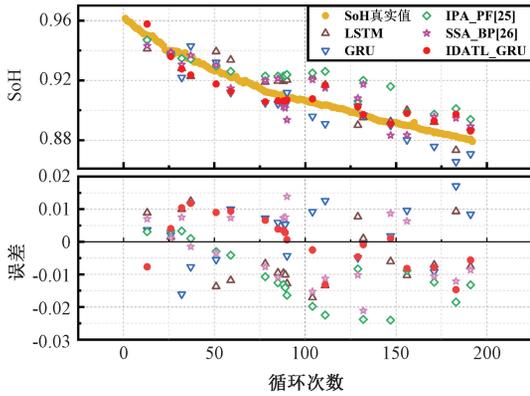


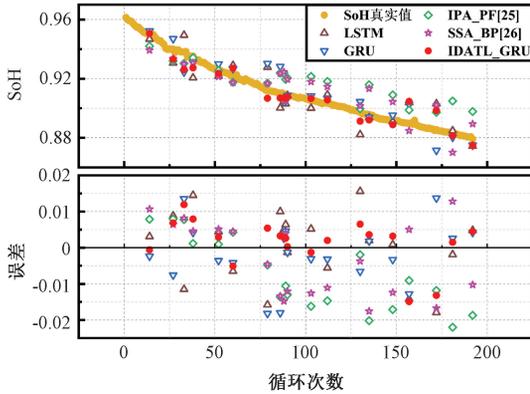
图 6 与主流预测算法对比

Fig. 6 Comparison with mainstream prediction algorithms

由图 7 和表 4 可知, 由于文献[25-26]中的网络结构对时间序列数据的拟合能力不如 LSTM 和 GRU, 相比 LSTM 和 GRU, 误差更大。本文 IDATL_GRU 模型相比于 IFA_PF 模型, 当测试倍率为 0.75 C 时, MAE 和 RMSE 分别降低了 45.76% 和 45.32%; 测试倍率为 0.5 C 时, 分别降低了 55.05% 和 48.80%。相比于 SSA_BP 模型, 当测试倍率为 0.75 C 时, MAE 和 RMSE 分别降低了 29.67% 和 25.49%; 测试倍率为 0.5 C 时, 分别降低了 48.42% 和



(a) 0.75 C 恒流数据估计结果
(a) Estimation results of 0.75 C constant current data



(b) 0.5 C 恒流数据估计结果
(b) Estimation results of 0.5 C constant current data

图 7 不同模型估计结果

Fig. 7 Estimation results of different models

表 4 不同模型的估计误差

Table 4 Estimation errors of different models

测试倍率/C	模型	MAE/%	RMSE/%
0.75	LSTM	0.91	1.00
	GRU	0.73	0.85
	IFA_PF ^[25]	1.18	1.39
	SSA_BP ^[26]	0.91	1.02
	IDATL_GRU	0.64	0.76
0.5	LSTM	0.78	0.94
	GRU	0.66	0.85
	IFA_PF ^[25]	1.09	1.25
	SSA_BP ^[26]	0.95	1.05
	IDATL_GRU	0.49	0.64

39.48%。另外,GRU 的估计精度整体优于 LSTM,这是由于所提估计方法训练数据较少,而当训练数据为中小规模数据集时,GRU 参数更少,更容易收敛^[27]。相比基于 LSTM 和 GRU 的方法,基于 IDATL 的 GRU 算法整体拥有更高的估计精度。IDATL_GRU 模型与基于 LSTM 的模型相比,当测试倍率为 0.75 C 时,MAE 和 RMSE 分别降低了 29.67%和 24.0%;测试倍率为 0.5 C 时,分别降低

了 37.18%和 31.91%。与基于 GRU 的模型相比,当测试倍率为 0.75 C 时,MAE 和 RMSE 分别降低了 12.33%和 10.59%;测试倍率为 0.5 C 时,分别降低了 25.76%和 24.71%。这得益于离线训练中,迁移学习可以使目标模型从源模型中学习更多的先验知识,经历有限的迭代训练后,具有更高的估计精度。

为进一步验证新型估计方法在计算负荷方面的特点,本文采用 3 台不同配置的计算机对上述模型进行仿真,3 台计算机核心配置如下:C₁ 为内存 16 G,CPU 为 AMD-Ryzen7-5800,GPU 为 3050Ti;C₂ 为内存 32 G,CPU 为 Intel7-12700,无 GPU;C₃ 为内存 32 G,CPU 为 Intel7-12700,GPU 为 3070Ti。模型运行时间如表 5 所示,仿真时间为 0.75 和 0.5 C 恒流充电数据下 3 台计算机仿真时间平均值。

表 5 不同模型仿真时间

Table 5 Simulation time of different models

模型	迭代次数	仿真时间/s			平均值
		C ₁	C ₂	C ₃	
LSTM	944	245.48	110.57	102.52	152.86
GRU	956	240.62	108.32	100.34	149.76
IFA_PF ^[25]	250	217.33	106.40	95.46	141.77
SSA_BP ^[26]	300	260.09	109.85	98.12	156.02
IDATL_GRU	200	201.21	81.66	79.35	120.74

由表 5 可知,基于 IDATL 的 GRU 算法模型平均仿真时间为 120.74 s,相比基于 LSTM、GRU、IFA-PF 和 SSA-BP 的估计方法分别提高了 21.01%、19.38%、14.83%和 22.61%。这是因为在基于 IDATL 的 GRU 模型中,迁移学习向目标模型中迁移了源模型训练好的参数,使得模型无需从头训练,只需更少的迭代次数即可使模型参数训练至最优结果。

4.2 与其他基于 TLN 的 SOH 估计方法对比

为验证 IDATL 相比于其他类型 TLN 算法的先进性,以文献[22, 28]设计的 TLN 算法作为比较对象,测试数据类型与 4.1 节相同,对比过程如图 8 所示。

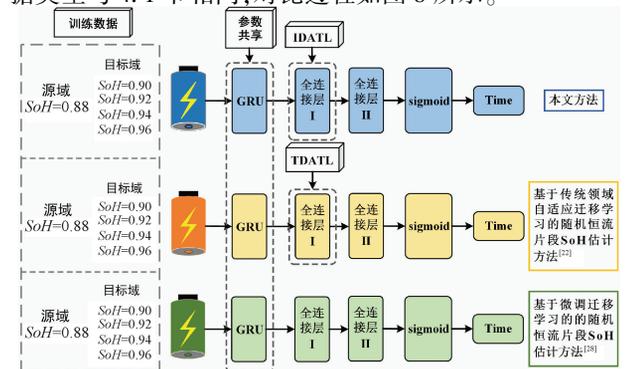


图 8 与其他迁移学习算法对比

Fig. 8 Comparison process with other TLNs

对比模型中,3种算法的GRU神经元数目均为15,全连接层I和全连接层II的神经元数目分别为10和1。本文方法与文献[22]方法中非负自适应正则化参数 λ 均为5,非负阈值参数 m 为0.5。比较结果如图9和表6所示。

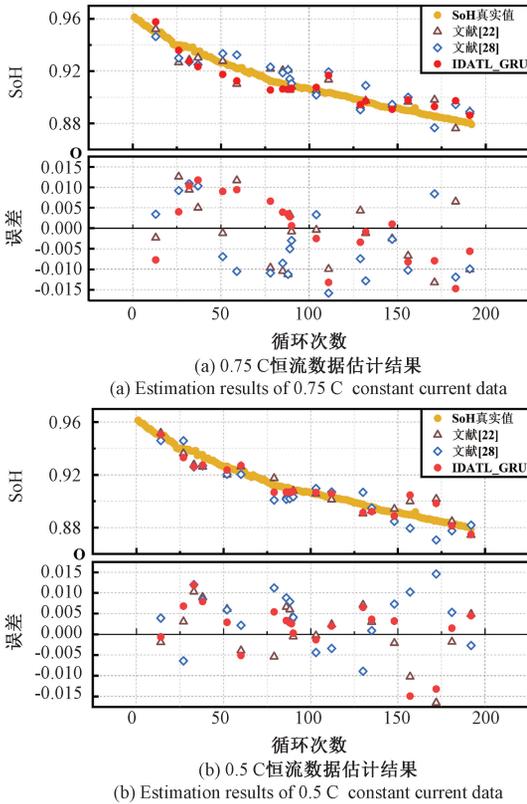


图9 不同迁移学习模型对比结果

Fig. 9 Comparison results of different TLN models

表6 不同迁移学习模型的误差对比

Table 6 Errors for different TLNs

测试倍率/C	模型	MAE/%	RMSE/%
0.75	文献[22]	0.66	0.79
	文献[28]	0.83	0.92
	IDATL_GRU	0.64	0.76
0.5	文献[22]	0.52	0.69
	文献[28]	0.66	0.75
	IDATL_GRU	0.49	0.64

由图9和表6可知,3种模型均具有良好的估计结果,本文IDATL_GRU模型相比于基于传统领域自适应迁移学习的SOH估计方法^[22],测试倍率为0.75C时,MAE和RMSE分别降低了3.0%和3.8%;测试倍率为0.5C时,分别降低了5.8%和4.3%。相比于基于微调迁移学习的估计方法^[28],测试倍率0.75C时,MAE和RMSE分别降低了22.9%和17.4%;测试倍率为0.5C时,降低了25.8%和14.7%。模型验证结果表明了本文

所提新型SOH估计方法和目前主流方法相比,具有更好的估计精度。IDATL_GRU模型整体精度优于其他两种模型的原因在于文献[22]的迁移学习方法通过MMD来表征域间差异,具有优良的拟合性能,但无法克服训练后期负迁移带来的影响。文献[28]通过微调的迁移学习方法使目标模型无需从头开始训练,但不同程度的老化数据导致源域和目标域的特征分布存在差异,造成模型泛化能力一般。

表7为3种迁移学习算法模型的仿真时间,仿真时间为0.75和0.5C恒流充电数据下3台计算机仿真时间的平均值。

表7 不同迁移学习算法仿真时间

Table 7 Simulation time for different TLNs

模型	迭代次数	仿真时间/s			平均值
		C ₁	C ₂	C ₃	
文献[22]	320	266.13	118.47	109.98	164.86
文献[28]	704	210.33	85.92	81.64	125.96
IDATL_GRU	200	201.21	81.66	79.35	120.74

由表7可知,本文IDATL_GRU模型的平均仿真时长为120.74s,相比于文献[22,28]的模型,运算速度分别提高了26.76%和4.14%。基于上述对比结果可知,本文所提估计方法估计精度更高,且具有更快的运算速度,验证了本文的理论分析。

5 结论

针对基于数据驱动的SOH估计方法适用性差且计算量大的不足,提出一种基于改进领域自适应迁移学习的锂电池SOH估计方法。首先,为适应完整充电曲线不易获取并简化SOH估计模型的输入,设计了一种基于等充电电压差时间间隔的SOH特征参数,使得网络模型的输入可以为任意恒流充电片段的电流及起始电压,从而简化SOH估计模型的输入参数。其次,为克服传统迁移学习训练后期存在的负迁移问题,基于双曲正切函数,提出了一种改进领域自适应迁移学习算法,使得迁移深度随迭代次数增加而逐渐降低,有效避免了负迁移出现的可能且缩短了模型运行时间。最后,基于自主实验平台测试数据,将所提方法与同类型方法进行对比分析,所提方法在测试倍率为0.75C时,MAE和RMSE分别为0.64%、0.76%,测试倍率为0.5C时,MAE和RMSE分别为0.49%、0.64%,验证了所提方法在估计精度及模型速度方面的优势。未来的研究将会把温度也考虑进建模过程,针对不同温度条件下的锂电池设计更具应用前景的SOH估计方法。

参考文献

[1] 秦亚莉,杨续来. 锂离子电池膨胀特性检测方法研究

- 进展[J]. 仪器仪表学报, 2023, 44(12): 22-33.
- QIN Y L, YANG X L. Research progress on measuring methods for expansion of lithium-ion batteries [J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 22-33.
- [2] SUN R L, CHEN J SH, LI B CH, et al. State of health estimation for Lithium-ion batteries based on novel feature extraction and BiGRU-Attention model [J]. Energy, 2025, 319: 134756.
- [3] 金帅, 董静. 基于数据驱动的锂离子电池健康状态估计研究进展综述[J]. 仪器仪表学报, 2024, 45(3): 45-59.
- JIN SH, DONG J. Review on progress of data-driven based health state estimation for lithium-ion batteries[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 45-59.
- [4] HUANG P, ZHANG Y, KANG Y ZH, et al. A flexible screening scheme for retired lithium-ion batteries based on novel capacity indicator and random forest algorithm[J]. IEEE Transactions on Transportation Electrification, 2025, 11(1): 544-557.
- [5] SHU X, YANG H, LIU X, et al. State of health estimation for lithium-ion batteries based on voltage segment and transformer[J]. Journal of Energy Storage, 2025, 108: 115200.
- [6] 陈媛, 段文献, 何怡刚, 等. 带降噪自编码器的锂离子电池健康状态估计算法[J/OL]. 电工技术学报, 1-17 [2025-08-15]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231644>.
- CHEN Y, DUAN W X, HE Y G, et al. State of health estimation algorithm of lithium ion battery with denoising autoencoder [J/OL]. Transactions of China Electrotechnical Society, 1-17 [2025-08-15]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231644>.
- [7] SAHAR K, MDSAZZAD H, DANIAL K, et al. Developing an online data-driven approach for prognostics and health management of lithium-ion batteries [J]. Applied Energy, 2022, 308: 118348.
- [8] QUAN R, ZHOU Y L, LI W, et al. A hybrid data-driven approach for SOH estimation of lithium-ion batteries based on health index extraction and QHDBO-BiTCN-BiGRU[J]. Journal of Energy Storage, 2025, 125: 116788.
- [9] LIN M Q, WU D G, MENG J H, et al. Health Prognosis for Lithium-Ion Battery with Multi-Feature Optimization[J]. Energy, 2023, 264: 126307.
- [10] HUANG ZH L, XU F, YANG F F. State of health prediction of lithium-ion batteries based on autoregression with exogenous variables model[J]. Energy, 2023, 262: 125497.
- [11] ZHU X F, WANG W, ZOU G P, et al. State of health estimation of lithium-ion battery by removing model redundancy through aging mechanism [J]. Journal of Energy Storage, 2022, 52: 105018.
- [12] JULIUS S, MATHIAS R, ALEXANDER K, et al. Capacity and degradation mode estimation for lithium-ion batteries based on partial charging curves at different current rates [J]. Journal of Energy Storage, 2023, 59: 106517.
- [13] LI N, HE F X, MA W T, et al. An indirect state-of-health estimation method based on improved genetic and back propagation for online lithium-ion battery used in electric vehicles [J]. IEEE Transactions on Vehicular Technology, 2022, 71(12): 12682-12690.
- [14] ZHANG F, XING Z X, WU M H. State of health estimation for li-ion battery using characteristic voltage intervals and genetic algorithm optimized back propagation neural network [J]. Journal of Energy Storage, 2023, 57: 106277.
- [15] PAN C Y, PENG Z X, YANG S C, et al. Adaptive neural network-based prescribed-time observer for battery state-of-charge estimation [J]. IEEE Transactions on Power Electronics, 2023, 38(1): 165-176.
- [16] ZHAO X Y, WANG Z L, HAN T, et al. A meta-learning method for few-shot multidomain state-of-health estimation of lithium-ion batteries[J]. IEEE Transactions on Transportation Electrification, 2025, 11(1): 4830-4840.
- [17] MA Y, SHAN C, GAO J W, et al. Multiple health indicators fusion-based health prognostic for lithium-ion battery using transfer learning and hybrid deep learning method[J]. Reliability Engineering and System Safety, 2023, 229: 108818.
- [18] XING Q K, ZHANG M, FU Y P, et al. Transfer learning to estimate lithium-ion battery state of health with electrochemical impedance spectroscopy [J]. Journal of Energy Storage, 2025, 110: 115345.
- [19] LI X P, ZHAO M H, ZHONG S S, et al. Deep transfer learning enabled online state-of-health estimation of lithium-ion batteries under small samples across different cathode materials, ambient temperature and charge-discharge protocols[J]. Journal of Power Sources, 2025, 650: 237503.
- [20] ZHAO G C, ZHANG CH H, DUAN B, et al. State-of-health estimation with anomalous aging indicator detection of lithium-ion batteries using regression generative

- adversarial network[J]. IEEE Transactions on Industrial Electronics, 2023, 70(3): 2685-2695.
- [21] MA G J, XU S P, YANG T, et al. A transfer learning-based method for personalized state of health estimation of lithium-ion batteries [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35 (1): 759-769.
- [22] ISAlAH O, ABDALLAH C, YOUNGKI K. A controllable deep transfer learning network with multiple domain adaptation for battery state-of-charge estimation [J]. Applied Energy, 2022, 312: 118726.
- [23] 张朝龙, 罗来劲, 刘惠汉, 等. 基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计 [J]. 电子测量与仪器学报, 2023, 37(1): 167-176.
ZHANG CH L, LUO L J, LIU H H, et al. State of health estimation of Lithium-ion batteries based on incremental energy analysis and BiGRU-Dropout [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 167-176.
- [24] 潘大为, 师杰, 杜宇航, 等. 基于 BNN-PF 的卫星锂离子电池多工况 SOH 估计 [J]. 电子测量与仪器学报, 2024, 38(9): 104-115.
PAN D W, SHI J, DU Y H, et al. BNN-PF-based SOH estimation of satellite lithium-ion batteries under different operating conditions [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (9): 104-115.
- [25] OUYANG T CH, YE J L, XU P H, et al. Estimation of state-of-charge and state-of-health for lithium-ion battery based on improved firefly optimized particle filter [J]. Journal of Energy Storage, 2023, 68: 107733.
- [26] 赵靖英, 胡劲, 张雪辉, 等. 基于锂电池模型和分数阶理论的 SOC-SOH 联合估计 [J]. 电工技术学报, 2023, 38(17): 4551-4563.
ZHAO J Y, HU J, ZHANG X H, et al. Joint estimation

of the SOC-SOH based on lithium battery model and fractional order theory [J]. Transactions of China Electrotechnical Society, 2023, 38(17): 4551-4563.

- [27] 刘少卿, 李帅, 苗建国, 等. 基于 TCN-BiGRU 的锂离子电池健康状态评估 [J]. 电子测量技术, 2023, 46(23): 68-76.
LIU SH Q, LI SH, MIAO J G, et al. Lithium-ion battery state of health estimation based on TCN-BiGRU [J]. Electronic Measurement Technology, 2023, 46(23): 68-76.
- [28] SHU X, SHEN J W, LI G, et al. A flexible state-of-health prediction scheme for lithium-ion battery packs with long short-term memory network and transfer learning [J]. IEEE Transactions on Transportation Electrification, 2021, 7(4): 2238-2248.

作者简介



郭向伟 (通信作者), 2016 年于华南理工大学获得博士学位, 现为河南理工大学副教授, 主要研究方向为电力电子及其在电池管理系统中的应用。

E-mail: gxw@hpu.edu.cn

Guo Xiangwei (Corresponding author)

received his Ph. D. degree from South China University of Technology in 2016. Now he is an associate professor in Henan Polytechnic University. His main research interests include power electronics and their applications in battery management systems.



袁江龙, 2023 年于河南理工大学获得学士学位, 现为河南理工大学硕士研究生, 主要研究方向为车载动力电池的状态估计。
E-mail: yuanjianglong034@163.com

Yuan Jianglong received his B. Sc.

degree from Henan Polytechnic University in 2023. Now he is a M. Sc. candidate at Henan Polytechnic University. His main research interest includes state estimation of vehicle power batteries.