

DOI: 10.13382/j.jemi.B2407999

基于物理信息神经网络的锂电池 SOH 估计*

谢国民 刘 澳

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要: 锂电池健康状态(SOH)的准确估计对于优化电池设计至关重要。然而,由于电池内部复杂的降解机制,准确的电池SOH估计仍然具有挑战性。为此,提出了一种基于充电电压曲线和物理信息神经网络(PINN)的SOH估计方法。首先利用Spearman相关性分析从充电电压曲线的恒流段提取电池老化特征并建立电池SOH退化的偏微分方程模型;其次利用添加了物理信息约束的神经网络逼近该隐式模型;然后利用向量加权平均(INFO)算法的加权平均和收敛加速技术优化PINN超参数以提高方法的估计精度;最后利用该方法在MIT、CALCE和NASA 3个公开数据集上进行SOH估计。结果表明,所提方法在充电策略变化的MIT测试集上的平均RMSE为0.2716%,与长短期记忆网络(LSTM)、卷积神经网络(CNN)、基线神经网络(BNN)等方法相比,误差分别减小了80.74%、57.48%、74.73%;在CALCE测试集和NASA测试集上的估计精度均在97%以上。证明了该方法较高的估计精度,且对电极材料及实验条件的变化具有较好的鲁棒性。

关键词: PINN; Spearman相关性分析; 偏微分方程; 向量加权平均; 物理信息约束

中图分类号: TM912; TN19.5 **文献标识码:** A **国家标准学科分类代码:** 41310

SOH estimation of lithium-ion batteries based on physics-informed neural network

Xie Guomin Liu Ao

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Accurate estimation of the state of health (SOH) of lithium-ion batteries is crucial for optimizing battery design. However, accurate SOH estimation remains challenging due to the complex degradation mechanism within the battery. Therefore, a SOH estimation method based on charging voltage curve and physics-informed neural network (PINN) is proposed. Firstly, Spearman correlation analysis is used to extract battery aging characteristics from the constant current segment of the charging voltage curve and establish a partial differential equation model for battery SOH degradation. Secondly, using a neural network with added physics-informed constraints to approximate the implicit model. Then, the weighted average and convergence acceleration techniques of the weighted mean of vectors (INFO) algorithm are utilized to optimize the PINN hyperparameters and improve the estimation accuracy of the method. Finally, this method is used for SOH estimation on three publicly available datasets: MIT, CALCE, and NASA. The results show that the average RMSE of the proposed method on the MIT test set with changes in charging strategy is 0.2716%. Compared with long short-term memory network (LSTM), convolutional neural network (CNN) and baseline neural network (BNN) methods, the error is reduced by 80.74%, 57.48% and 74.73%, respectively. The estimation accuracy on both the CALCE and NASA test sets is above 97%. This proves that the method has high estimation accuracy and good robustness to changes in electrode materials and experimental conditions.

Keywords: PINN; Spearman correlation analysis; partial differential equation; weighted mean of vectors (INFO); physics-informed constraints

0 引言

伴随着能源危机问题,电动汽车的发展成为可持续发展的选择^[1-2]。其中锂电池凭借能量密度高^[3]、电化性能好和循环寿命长^[4]等优势成为诸多电动汽车厂商的首选。然而,随着使用次数的增加,电池的性能逐渐下降^[5],这将严重影响电池汽车的续航里程和行驶安全。健康状态(state of health, SOH)作为评价电池性能的重要指标,准确估计它可以保障电池系统的可靠性和安全性^[6]。

现在的电池 SOH 估计方法主要分为机理模型方法和数据驱动方法^[7]。机理模型方法主要是基于电池衰减机理构建物理模型来估计电池 SOH。其主要可以分为电化学机理模型、等效电路模型和经验退化模型^[8]。文献[9]考虑了双层电阻增加、固体电解质界面薄膜的生长、阴极聚集体裂纹扩展和温度的影响建立了一个电化学-热老化耦合模型。文献[10]采用二阶 RC 等效电路模型对锂电池建模。文献[11]提出了一种考虑电解质极化和老化机制的分数阶模型,并在较低的计算复杂度下实现了较好的 SOH 估计。由于电池内部反应机制过于复杂^[12],且这些反应发生耦合^[13-14],所以开发可以在各种衰老条件下适用的机理模型仍具有挑战性。

数据驱动方法无需专业的理论知识,直接从大量的电池充放电数据中提取电池老化特征^[15],并利用各种机器学习方法将其映射到容量退化^[16]。文献[17]将容量退化分解为退化趋势部分和容量再生部分,并分别用线性回归模型预测电池容量的退化趋势,转置 Transformer 模型估计电池容量再生部分,两部分组合以估计电池 SOH。文献[18]提出了一种结合监督和自监督学习的协同学习框架估计电池容量,用于处理无标签和有噪声的容量数据。虽然该数据驱动方法有较好的 SOH 估计精度,但其准确性和泛化能力是建立在大量高质量数据的基础上的。

鉴于机理模型方法可以提供电池老化机制的深度信息,数据驱动方法强大的从数据中学习未来健康趋势的能力,文献[19]提出利用二者的混合方法——物理信息神经网络(physics-informed neural network, PINN),求解基于偏微分方程的动态电池模型以估计 SOH。具体来说, PINN 利用神经网络的自动微分和通用函数逼近器功能^[20-21],基于底层物理信息约束在少量数据的情况下,对观测电池系统的非线性偏微分方程进行求解从而估计 SOH。因此,利用 PINN 建模电池退化具有巨大的潜力。

本文提出了一种基于向量加权平均(weighted mean of vectors, INFO)算法的物理信息神经网络模型(INFO-

PINN)来估计电池 SOH。该方法首先构建了一个描述电池 SOH 衰退的偏微分方程模型;接着将利用 Spearman 相关性分析提取的电池电压特征作为 PINN 的输入以学习该 SOH 衰退模型的映射关系,并利用融合了数据驱动损失和偏微分方程损失的损失函数优化 PINN 的学习过程;然后利用 INFO 算法优化 PINN 超参数以提高方法的估计精度。INFO 算法通过运用基于加权平均的更新规则和向量组合策略,实现了全局范围内的搜索,有效避免了陷入局部最优解。最后,利用 MIT、CALCE、NASA 3 个公开数据集进行实验分析,并与长短期记忆网络(long short-term memory, LSTM)、卷积神经网络(convolutional neural network, CNN)以及基线神经网络(baseline neural network, BNN)进行对比分析,证明了本文所提 INFO-PINN 方法在电池 SOH 估计上具有较高的精度,验证了所提方法的有效性。

1 数据集介绍与 SOH 定义

本文采用了 Severson 等^[22]的磷酸锂离子/石墨电池数据集的 20 个电池、美国马里兰大学公开的 CALCE 电池数据集的 10 个 CS2 系列电池和 NASA 研究中心的公开电池数据集中的 10 个电池数据进行分析。为方便起见将其记为 MIT 数据集、CALCE 数据集和 NASA 数据集。电池基本信息如表 1 所示。

表 1 数据集的基本信息

Table 1 Basic information of the dataset

数据集	电池材料	数量	上下截止电压/V	标称容量/Ah
MIT	LiFePO ₄	20	3.6~2.0	1.1
CALCE	LiCoO ₂	10	4.2~2.7	1.1
NASA	未知	10	4.2~[2.0, 2.7]	2.0

MIT 数据集电池的标称容量为 1.1 Ah,标称电压为 3.3 V。此数据集中的所有电池都使用一步或两步快速充电策略进行充电。该策略的格式为“C1(Q1)-C2”,其中 C1 和 C2 分别是第 1 和第 2 恒流步长, Q1 是电流切换时的充电状态(SOC, %),是变化的。第 2 个电流步骤在 80%SOC 结束,之后电池采用 1 C(1.1 A)速率恒流恒压(CC-CV)充电至 3.6 V。所有电池都在 4 C 速率下放电至 2.0 V。具体充电策略如图 1 所示。

CALCE 数据集的电池的标称容量为 1.1 Ah,标称电压为 4.2 V。所有 CS2 系列电池都先由 0.5 C 速率恒定电流充电至 4.2 V 然后恒压充电至电流下降到低于 0.05 A。NASA 数据集电池的标称容量为 2.0 Ah,标称电压为 4.2 V。所有电池在 4 °C 和 24 °C 下进行充放电循环测试和阻抗测试。所有电池的充电策略是相同的,但

电池的放电策略是多样的,其使用多个负载电流水平(2 和 4 A)在不同的截止电压(2.0、2.2、2.5 和 2.7 V)处停止放电。

本文的电池 SOH 定义为电池实际容量与其额定容量的比值,如式(1)所示。

$$SOH = \frac{Q_c}{Q_0} \quad (1)$$

式中: Q_c 为电池当前可用容量; Q_0 为电池额定容量。

2 基于充电电压曲线的特征提取

2.1 特征提取

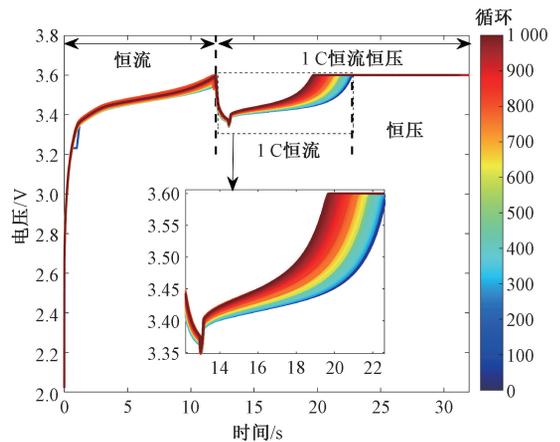
在电动汽车的实际使用过程中,从电池装车的那一刻,作为直接健康因子的电池真实容量就很难测量,除非是进行专门的线下容量测试。为此,需要选择间接特征来表征电池健康状况。而在电动汽车的实际运行过程中电压曲线可以通过电池管理系统(battery management system, BMS)获得,所以考虑使用充电过程中电压曲线的特征来表征电池健康状况。电池充电过程中电压变化曲线如图 1 所示。图 1(a) 为采用一步快速充电策略的充电电压曲线,图 1(b) 为采用两步快速充电策略的充电电压曲线。可以发现随着电池充电次数的增加,电池恒流充电时间逐渐缩短,尤其是 1 C 恒流充电阶段的电压曲线发生显著的变化。

所以本文选取电池充电过程中电压曲线的恒流充电时间(cct)、1 C 恒流充电阶段电压曲线关于充电时间的积分(area)、1 C 恒流充电阶段电压的平均值(mean)、标准差(std)、偏度(skew)、峰度(kurt)、斜率(slope)和曲线熵(entropy)等 8 个特征进行分析。

2.2 相关性分析

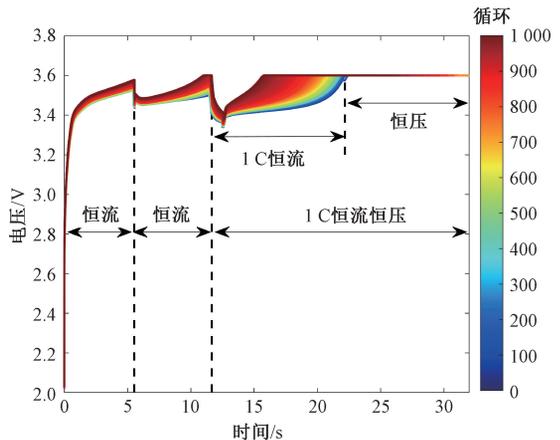
为了量化这 8 个特征与电池 SOH 的相关性,计算了其 SOH 的 Spearman 相关性系数。图 2 所示为电池 M1~M20 的 8 个特征的相关性系数。图 2 横坐标的特征 1~8 分别为 cct、area、mean、std、skew、kurt、slope 和 entropy。

由图 2 可知,cct、area、skew、kurt 与 SOH 均有较强的正相关性,其中大部分电池与 SOH 的 Spearman 相关性系数均达到了 0.95 以上。特征 mean 和 slope 与 SOH 有较强的负相关性,大部分电池与 SOH 的 Spearman 相关性系数的绝对值也达到了 0.95 以上。另外,虽然大部分电池的 entropy 与 SOH 的相关性较强,但电池 M6 与 M7 的 entropy 与 SOH 的相关性较弱,Spearman 相关性系数分别为 -0.444 4 和 -0.588 9。特征 std 与 SOH 的相关性较弱。因此,为了充分揭示每个电池的老化状况,本文选择 cct、area、mean、skew、kurt 和 slope 作为输入特征。



(a) 采用一步快速充电策略的电压曲线

(a) Voltage curve using a one-step fast charging strategy



(b) 采用两步快速充电策略的电压曲线

(b) Voltage curve using a two-step fast charging strategy

图 1 不同循环的电池充电电压曲线

Fig. 1 Charging voltage curve of batteries with different cycles

3 基于 INFO-PINN 的 SOH 估计模型

3.1 SOH 退化模型

由于电池内部复杂的降解机制,仅将电池 SOH 的退化轨迹描述为时间的函数是不够的,需要将其描述为多变量的函数。由图 2 可知,提取的充电过程中的电压特征与电池 SOH 有极强的相关性,说明随着电池循环次数的增加,电压曲线发生显著的变化,能够反映电池内部的降解机制。所以本文将电池的 SOH 退化轨迹建模为电压特征的函数:

$$y = f(t, x) \quad (2)$$

式中: y 为 SOH 值; $f(\cdot)$ 为 SOH 退化轨迹的隐式函数; t 为时间; x 为电压特征组成的向量。

在电池循环充电过程中,会发生内部化学反应、电荷传输和电解质运输等动力学现象,它们会进一步导致电池性能下降,这一过程称为电池的动力学降解,其对研究电池老化具有重要意义。为了研究该过程,首先计算电

1	0.976 9	0.987 3	-0.897 7	-0.334 9	0.834 7	0.769	-0.976 6	-0.860 2
2	0.989 7	0.990 1	-0.907 8	-0.396 8	0.850 4	0.798 9	-0.991	-0.804 2
3	0.990 8	0.990 9	-0.895 3	-0.318 2	0.845 1	0.772 5	-0.990 8	-0.782 4
4	0.990 3	0.990 3	-0.939 4	-0.569	0.917 6	0.861 8	-0.984 7	-0.861 2
5	0.989 6	0.989 5	-0.919 2	-0.484 7	0.875 1	0.822 7	-0.988 7	-0.851 1
6	0.992 3	0.910 8	-0.955 2	-0.576 6	0.911 3	0.807 3	-0.733 9	-0.444 4
7	0.993 9	0.937 2	-0.976 4	-0.373 9	0.926 3	0.850 9	-0.957 6	-0.588 9
8	0.996 4	0.995 4	-0.976 6	-0.754 2	0.967 8	0.950 8	-0.951 2	-0.859 1
9	0.996 4	0.994 8	-0.983 5	-0.736	0.967 1	0.926 3	-0.984 6	-0.891 8
10	0.996 9	0.995 5	-0.981 5	-0.658 8	0.969 2	0.956	-0.978 9	-0.901 7
11	0.994	0.992 3	-0.983 3	-0.686 6	0.969 7	0.950 9	-0.973	-0.889 1
12	0.985	0.978 5	-0.978 8	-0.631 8	0.961 5	0.936 8	-0.954 5	-0.852 7
13	0.994 3	0.992	-0.982 3	-0.833 4	0.971 9	0.962 8	-0.967	-0.853 1
14	0.995 4	0.993 6	-0.981 5	-0.758 7	0.964 9	0.954 2	-0.978 9	-0.870 6
15	0.994 6	0.992 8	-0.981 7	-0.709 4	0.972 9	0.96	-0.982 3	-0.91
16	0.994 6	0.992	-0.979 9	-0.617 5	0.968 3	0.951 8	-0.975 4	-0.858
17	0.991 5	0.991 7	-0.969 5	-0.750 9	0.956 8	0.941 4	-0.974 5	-0.839 6
18	0.992 9	0.989 4	-0.977 2	-0.780 9	0.969 3	0.949	-0.964	-0.845 4
19	0.998	0.995 4	-0.985 5	-0.465 8	0.971	0.951 5	-0.994 8	-0.966
20	0.998 2	0.997 4	-0.987 9	-0.723 3	0.981 9	0.945 6	-0.989 4	-0.936 8
	1	2	3	4	5	6	7	8

特征

图2 8个特征的 Spearman 相关性系数

Fig. 2 Spearman correlation coefficients for 8 features

池 SOH 衰减率:

$$\frac{\partial y}{\partial t} = g(t, x, y; \theta) \quad (3)$$

式中: $\partial y / \partial t$ 为 y 对时间 t 的偏导; $g(\cdot)$ 为 t, x 和 y 的非线性函数, 表示电池内部退化的动态。

对于电池的动力学降解, $g(\cdot)$ 不仅和 y 有关, 还和 y 关于 t 和 x 的各阶偏导数有关, 它们表示电池内部各种退化机制。但添加高阶偏导数的 SOH 退化模型更复杂, 利用神经网络进行逼近时会导致模型过拟合, 从而使模型的精度变差。所以为了平衡模型的计算复杂度和精度, 只考虑一阶偏导数对电池动力学降解的影响。为此, 考虑使用具有参数 θ^* 的函数 $g^*(\cdot)$ 来代替 $g(\cdot)$, 则式(3)变为:

$$y_i = g^*(t, x, y, y_t, y_x; \theta^*) \quad (4)$$

式中: y_t 为 y 对 t 的偏导, 等价于 $\partial y / \partial t$; y_x 为 y 对 x 的一阶偏导数。

然后考虑使用具有可学习参数 Φ 的神经网络 $Y(t, x; \Phi)$ 逼近 $f(t, x)$, 可学习参数 Θ 的神经网络 $G(\cdot)$ 逼近 $g^*(\cdot)$, 则式(4)变为:

$$F: \frac{\partial Y(t, x; \Phi)}{\partial t} = G(t, x, y, y_t, y_x; \Theta) \quad (5)$$

式中: F 为利用神经网络定义的 SOH 退化模型。

3.2 物理信息神经网络

为了更好地训练 3.1 节提出的 SOH 退化模型, 需要

添加损失函数对其进行优化。首先, 利用神经网络估计的 SOH 退化模型的值与 SOH 的真实值计算数据驱动损失:

$$L_1 = L_{MSE}(\hat{y}, y) = \frac{1}{N} \sum_{i=1}^N \|\hat{y}^i - y^i\|^2 \quad (6)$$

式中: \hat{y} 为 SOH 估计值; N 为样本数; \hat{y}^i 和 y^i 分别为第 i 个样本的 SOH 估计值与真实值。

其次, 为了使 SOH 的真实值 y 与退化轨迹 $f(\cdot)$ 上的点重合, 需要使 $F(t^i, x^i)$ 在每个采样点 i 去近似式(4)。所以 PINN 的优化过程需要满足式(4)规定的偏微分方程损失, 即:

$$L_2 = L_{MSE}(\hat{F}, F) = \frac{1}{N} \sum_{i=1}^N \|\hat{y}_t^i - G(t^i, x^i, \hat{y}_t^i, \hat{y}_x^i, \hat{y}_x^i; \Theta)\|^2 \quad (7)$$

式中: \hat{F} 为 SOH 估计值; t^i 和 x^i 分别为第 i 个样本的时间和电压特征; \hat{y}_t^i 和 \hat{y}_x^i 分别第 i 个样本的 SOH 关于时间 t 、电压特征 x 的一阶偏导数的估计值。

最后, 总的损失函数为:

$$L = L_1 + L_2 \quad (8)$$

自定义的总损失项直接体现了模型在更高层面上所要达成的最小化目标, 这一目标并非仅仅局限于模型真实值与估计值之间的误差。从根本上说, 训练过程的核心在于通过不断更新网络权重, 来逐步减小每次迭代中所计算出的自定义总损失项的值。如 3.1 节所述, 本文

建立的物理信息神经网络 PINN 由两部分组成,分别为模拟输入特征到 SOH 映射的神经网络 $Y(t, x; \Phi)$, 以及模拟电池退化动力学的神经网络 $G(\cdot)$ 。这两部分神经网络均由包含两个隐藏层的前馈神经网络组成,网络架构如图 3 所示。为了利用 PINN 模型中嵌入的物理信息,

采用了两步来估计 SOH。首先利用数据驱动损失来指导 PINN 的训练,使得网络能够初步学习输入的电压特征与 SOH 的关系;然后利用集成了物理信息约束的偏微分损失项优化 PINN 以学习 SOH 退化情况;最终得到了精确的 SOH 退化模型。

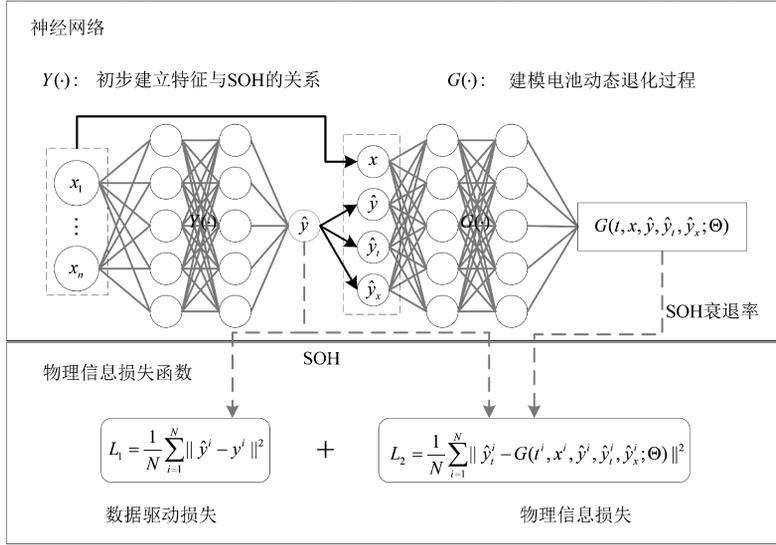


图 3 物理信息神经网络的结构

Fig. 3 Structure diagram of physics-informed neural network

3.3 INFO

本文使用向量加权平均优化算法 INFO 优化 PINN 的网络超参数。INFO 算法通过将均值规则应用于超参数组成的向量来更新向量的位置以找到最优解,主要包括更新规则阶段、向量组合阶段和局部搜索阶段。

1) 更新规则阶段

更新规则阶段的核心目标是提升种群在搜索过程中的多样性,这主要是通过计算一组随机向量的加权平均值来生成新的向量而实现的。具体来说,更新规则阶段包含两个关键环节:首先,利用均值规则 (MeanRule) 从一组随机选取的向量的加权平均中导出新的向量,以此作为向下一个解的过渡。此外,为了提升全局搜索能力,在更新规则算子中引入了收敛加速 (convergence acceleration, CA) 部分。该阶段的数学模型如式 (9) ~ (11) 所示。

$$\text{MeanRule} = \lambda_1 \times \text{WM}1_j^i + (1 - \lambda_1) \times \text{WM}2_j^i \quad (9)$$

$$\text{CA} = \lambda_2 \times \frac{(x_{bs}^i - x_{a1}^i)}{(f(x_{bs}^i) - f(x_{a1}^i) + \varepsilon)} \quad (10)$$

$$z_j^i = x_j^i + \sigma \times \text{MeanRule} + \text{CA} \quad (11)$$

式中: λ_1 为区间 $[0, 0.5]$ 之间的随机数; λ_2 为符合正态分布的随机数; WM 为向量的加权平均值; $j = 1, \dots, N_p$ 和 $i = 1, \dots, N$ 分别为种群数和迭代数; CA 为目标函数的

值; $f(x)$ 为 x 的适应度函数; x_{bs}^i 和 x_{a1}^i 分别为第 i 次迭代所有向量中最好的解向量与随机解向量, x_j^i 为第 i 次迭代中的第 j 个向量; ε 为常数; σ 为比例因子; z 为更新的新向量。

2) 向量组合阶段

在该阶段为了提高向量的局部搜索能力,将更新规则阶段中利用式 (11) 生成的两个向量 $z1_j^i$ 和 $z2_j^i$ 与向量 x_j^i 组合,生成新的向量 u_j^i 。

$$u_j^i = \begin{cases} z1_j^i + \mu |z1_j^i - z2_j^i|, & \text{rand}_1 < 0.5, \text{rand}_2 < 0.5 \\ z2_j^i + \mu |z1_j^i - z2_j^i|, & \text{rand}_1 < 0.5, \text{rand}_2 > 0.5 \\ x_j^i, & \text{rand}_1 > 0.5 \end{cases} \quad (12)$$

式中: u_j^i 为 $z1_j^i$ 和 $z2_j^i$ 组合获得的新向量; μ 等于 $0.05 \times \lambda_2$; rand_1 和 rand_2 为区间 $[0, 1]$ 之间的随机数。

3) 局部搜索阶段

有效的局部搜索能力可以防止 INFO 算法陷入局部最优解。INFO 算法利用全局位置和式 (13) 定义的基于均值的规则在局部区域上进行搜索,当适应度值不再显著增加时迭代结束,最终得到全局最优解。当 rand_1 和 rand_2 同时 < 0.5 时,第 1 行等式成立;当 $\text{rand}_1 < 0.5$ 和 $\text{rand}_2 > 0.5$ 时,第 2 行等式成立。 rand_1 和 rand_2 为区间 $[0, 1]$ 之间的随机数。

$$u_j^i = \begin{cases} \mathbf{x}_{bs}^i + randn \times (MeanRule + randn \times (\mathbf{x}_{bs}^i - \mathbf{x}_{al}^i)) \\ \mathbf{x}_{md}^i + randn \times (MeanRule + randn \times (\mathbf{v}_1 \times \mathbf{x}_{bs}^i - \mathbf{v}_2 \times \mathbf{x}_{md}^i)) \end{cases} \quad (13)$$

式中: \mathbf{x}_{md}^i 为随机组合 \mathbf{x}_{bs}^i 、 \mathbf{x}_{bt}^i 和 \mathbf{x}_{avg}^i 构成的解向量, \mathbf{x}_{bt}^i 和 \mathbf{x}_{avg}^i 分别为第 i 次迭代所有向量中较好的解向量与平均解向量; \mathbf{v}_1 和 \mathbf{v}_2 为两个随机数, 满足式 (14) 和 (15), 可以增加最佳位置对向量的影响。

$$\mathbf{v}_1 = \begin{cases} 2 \times rand, p > 0.5 \\ 1, p \leq 0.5 \end{cases} \quad (14)$$

$$\mathbf{v}_2 = \begin{cases} rand, p < 0.5 \\ 1, p \geq 0.5 \end{cases} \quad (15)$$

式中: $rand$ 和 p 均为区间 $[0, 1]$ 之间的随机数。

INFO 算法通过结合全局搜索与局部搜索策略, 利用更新规则和向量组合实现全局探索并避免局部最优, 同时采用加权平均和收敛加速技术确保快速收敛至最优解, 并且其更新规则算子增强了种群多样性, 促进了在解空间中的广泛探索。所构建的 INFO 算法如算法 1 所示。

算法 1 INFO 算法

步骤 1) 初始化

设置种群大小 N_p , 最大迭代数 N , 搜索空间的维度 k

生成初始种群 $P^0 = \{x_j^0, \dots, x_{N_p}^0\}$

计算每个向量个体的适应度值 $f(x_j^0)$, $j = 1, \dots, N_p$

确定最佳向量 x_{bs}

步骤 2) for $i = 1: N$ do

for $j = 1: N_p$ do

在范围 $[1, N_p]$ 随机选择 3 个个体

更新规则阶段

使用等式 (11) 计算向量 $z1_j^i$ 和 $z2_j^i$

向量组合阶段

使用等式 (12) 计算新的向量 u_j^i

局部搜索阶段

使用等式 (13) 计算局部搜索算子

计算向量 u_j^i 的适应度值 $f(u_j^i)$

if $f(u_j^i) < f(x_j^i)$ then $x_j^{i+1} = u_j^i$

otherwise $x_j^{i+1} = x_j^i$

end for

更新最佳向量 x_{bs}

end for

步骤 3) 返回向量 x_{bs}^i 作为最终结果

M8 为训练集, M9~M14 为验证集, M15~M20 为测试集。在训练过程中, 首先利用 INFO 算法设置超参数搜索范围并利用 Adam 优化器进行训练。Adam 优化器通过计算损失函数关于权重和偏置的梯度, 并沿着梯度的反方向更新参数值, 以逐步减小损失函数的值。这个过程是迭代进行的, 直到验证损失开始增加时终止训练, 此时超参数优化完成, 模型也训练完成。最后将测试集输入到训练好的 PINN 模型中估计电池 SOH。表 2 所示为优化后的网络超参数。

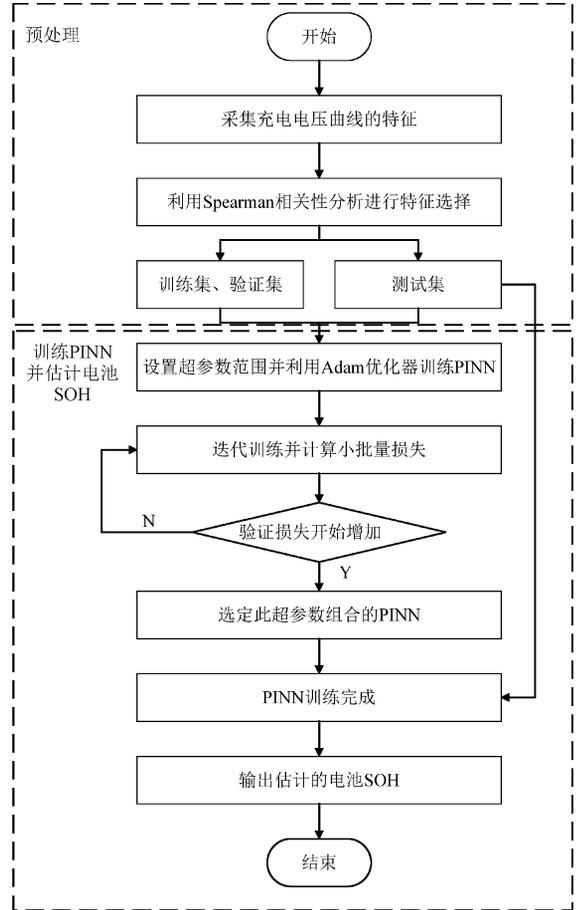


图 4 PINN 模型的 SOH 估计流程

Fig. 4 SOH estimation flowchart of PINN model

表 2 网络超参数

Table 2 Hyperparameters of the network

超参数	值
$Y(\cdot)$ 模块第 1 隐藏层神经元个数	10
$Y(\cdot)$ 模块第 2 隐藏层神经元个数	8
$G(\cdot)$ 模块第 1 隐藏层神经元个数	12
$G(\cdot)$ 模块第 2 隐藏层神经元个数	10
批处理大小	128
最大训练轮数	200

为了评估估计效果, 选择平均绝对百分比误差 (MAPE)、均方根误差 (RMSE)、平均绝对误差 (MAE) 和决定系数 R^2 作为评价指标, 其公式为:

4 实验结果分析

4.1 实验设置

提出的基于 PINN 的 SOH 估计模型的流程如图 4 所示。数据预处理环节, 首先提取充电电压曲线的特征, 并利用 Spearman 相关性分析选择与电池 SOH 相关性较高的特征。然后选用 MIT 数据集中 20 个电池的数据, 按照 4:3:3 的比例划分训练集、验证集和测试集。即 M1~

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (16)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (19)$$

式中: y_i 为实际值; \hat{y}_i 为估计值; \bar{y} 为所有 y_i 的均值; n 为样本数。

4.2 SOH 估计结果

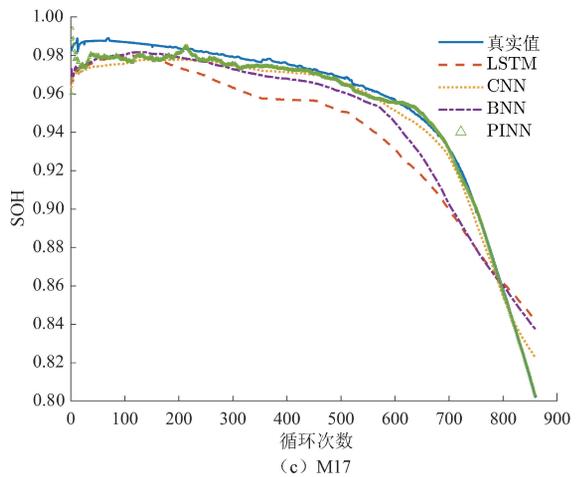
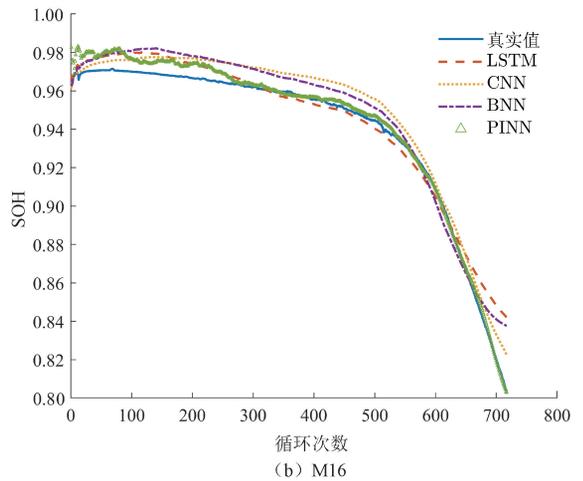
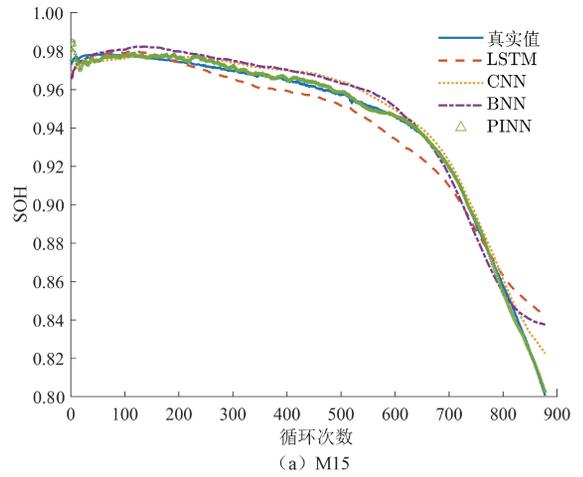
为了验证所提出的 PINN 的有效性, 将其与长短期记忆网络 LSTM、卷积神经网络 CNN 以及不添加物理信息的基线神经网络 BNN 在 MIT 数据集上进行对比分析。4 种网络模型的数据集划分情况及训练情况保持一致, SOH 估计误差的对比如表 3 所示。由表 3 可知, PINN 模型对采用不同充电策略的 6 个电池的 SOH 估计值的 MAPE 均小于 0.4%, RMSE 不超过 0.005, MAE 不超过 0.004, 说明了 PINN 模型的估计性能比较好。且这 6 个电池的 SOH 估计值的 R^2 也都大于 0.98, 更加证明了所提 PINN 模型的高估计性能。

表 3 不同模型估计结果的评价指标

Table 3 Evaluation indicators for estimation results of different models

模型	电池编号	MAPE/%	RMSE	MAE	R^2
LSTM	M15	0.717 4	0.009 2	0.006 5	0.957 4
	M16	0.697 1	0.008 8	0.006 4	0.953 5
	M17	1.830 8	0.019 0	0.017 3	0.815 8
	M18	1.555 7	0.017 8	0.014 5	0.830 2
	M19	1.267 9	0.013 3	0.011 6	0.889 7
	M20	2.391 8	0.024 9	0.022 6	0.732 4
CNN	M15	0.480 3	0.005 2	0.004 4	0.986 2
	M16	0.926 9	0.009 3	0.008 7	0.948 7
	M17	0.644 2	0.007 1	0.006 1	0.974 0
	M18	0.544 9	0.006 8	0.005 0	0.975 4
	M19	0.623 4	0.007 0	0.005 7	0.969 4
	M20	0.612 5	0.007 4	0.005 9	0.976 6
BNN	M15	0.612 6	0.007 2	0.005 6	0.973 9
	M16	0.922 8	0.009 7	0.008 6	0.943 6
	M17	1.142 6	0.012 9	0.010 7	0.914 6
	M18	0.789 7	0.009 4	0.007 3	0.952 8
	M19	1.065 8	0.011 7	0.009 7	0.914 4
	M20	1.914 6	0.019 9	0.018 0	0.829 9
PINN	M15	0.159 9	0.001 9	0.001 5	0.998 1
	M16	0.384 3	0.004 9	0.003 7	0.985 6
	M17	0.363 0	0.004 5	0.003 5	0.989 5
	M18	0.159 1	0.001 9	0.001 5	0.998 0
	M19	0.284 4	0.004 1	0.002 7	0.989 5
	M20	0.278 7	0.004 2	0.002 7	0.992 5

此外, 在 4 种模型中 PINN 模型在 6 个测试电池数据上的 MAPE、RMSE 和 MAE 的数值均是最小的, 且 R^2 也是最大的。以 6 个电池的平均误差为例, PINN 模型的平均 MAPE 为 0.271 6%, 相较于 LSTM、CNN 和 BNN 分别减小了 80.74%、57.48% 和 74.73%。本文所提模型与其余 3 种模型的估计结果对比如图 5 所示。由图 5 可知, 所提模型估计的电池 SOH 与实际值最为接近。为了进一步研究 4 种模型在 6 个测试电池上的估计性能, 图 6



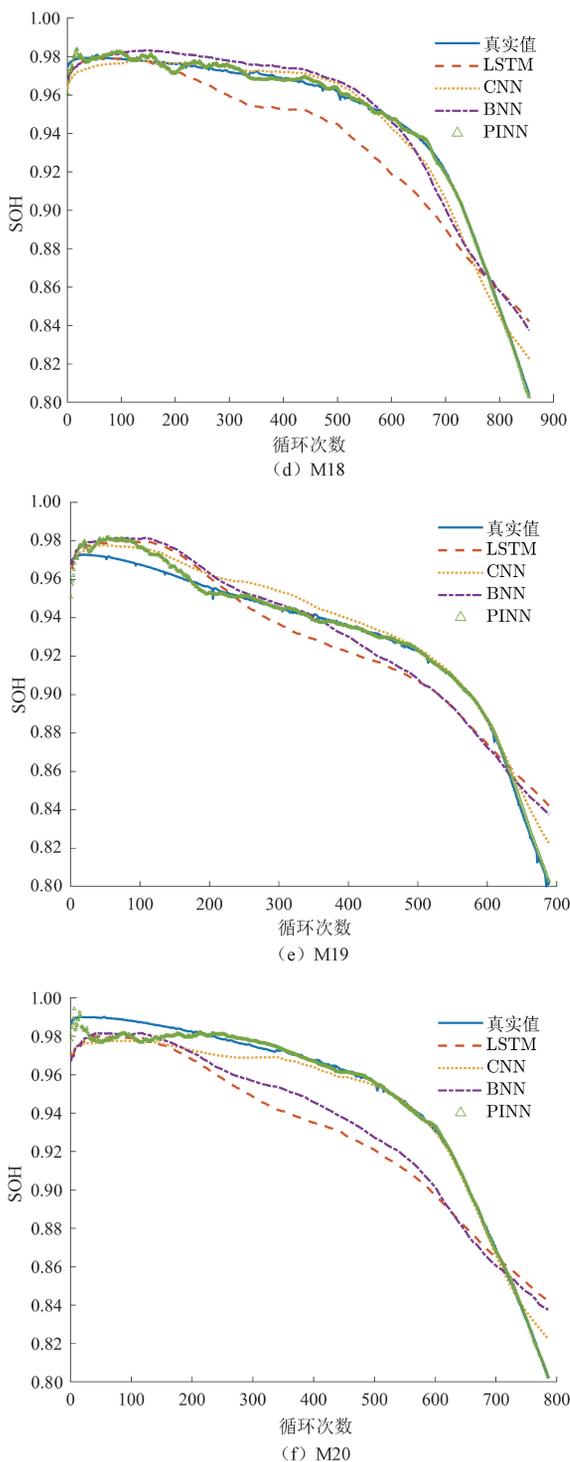


图 5 不同模型的 SOH 估计结果

Fig. 5 SOH estimation results of different models

所示为 4 种模型在 6 个测试电池上的估计误差的分布情况。可以发现 PINN 的平均测试误差比与其具有相同网络结构的 BNN 有了显著的改善。BNN 具有更大的误差范围,表明它在面对不同的测试条件时估计性能的变化很大。相比之下, PINN 在不同测试运行中误差范围较

小,能提供持续改进的性能。另外, CNN 也具有较小的误差范围,但其估计结果中出现了异常值,说明它在面对不同的测试条件时估计性能也会发生突变。LSTM 的误差条宽度最大,其效果是最差的。所以,在 MIT 数据集上 4 种网络模型的估计性能从高到低为 $PINN > CNN > BNN > LSTM$ 。

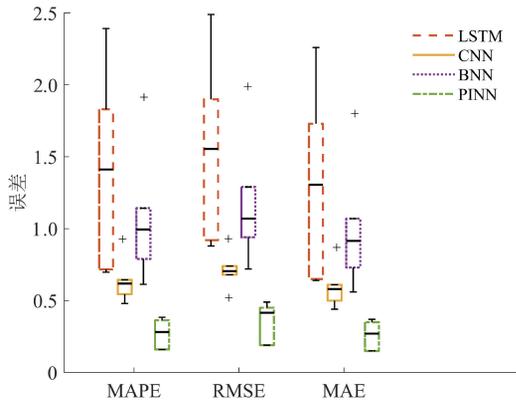


图 6 4 种模型整体性能的比较

Fig. 6 Comparison of overall performance of four models

综上所述,本文提出的 PINN 模型提供了将涉及复杂降解机制的 SOH 退化过程集成到损失函数中的优势,从而通过神经网络强大的数据分析能力和物理原理的约束来建立 SOH 退化模型,以实现 对 电 池 SOH 的 准 确 估 计。

4.3 对不同数据集的适用性

为了验证所提方法对不同电极材料、不同工况下电池 SOH 估计的适用性,本文分别选取美国马里兰大学公开的 CALCE 电池数据集的 CS2 系列的 10 个电池数据和 NASA 研究中心的公开电池数据集中的 10 个电池数据进行实验分析。数据集仍采用 4.1 节的 4 : 3 : 3 的比例进行划分。在 CALCE 数据集中,电池 CS2-3、CS2-8、CS2-9 和 CS2-21 用来训练,CS2-33、CS2-34 和 CS2-35 用来验证,CS2-36、CS2-37 和 CS2-38 用来测试。

在 NASA 数据集中,选取电池 B5、B6、B7、B18、B33、B34、B36、B54、B55 和 B56 进行验证分析。这 10 个电池在不同温度下经历了充电、放电和阻抗测试操作。且不同电池的放电电流速率和放电截止电压均是不同的。其中电池 B18、B33、B34 和 B36 用来训练,B54、B55 和 B56 用来验证,B5、B6 和 B7 用来测试。两个数据集均采用 SOH 估计流程(图 4)进行训练和测试,SOH 估计结果如图 7 所示。

由图 7(a) ~ (c) 可以看出,所提方法估计的 CALCE 电池的 SOH 与实际值基本吻合。图 7(d) ~ (f) 为 NASA 电池的 SOH 估计结果。可以发现,虽然复杂工况导致 SOH 在波动中下降,但所提方法仍然能准确地估计 SOH

的变化情况。为了进一步展示估计效果,图 7 中插图为 SOH 估计值的误差分布,可以发现估计误差集中在 0 附近且大体上呈正态分布。

此外,表 4 为 CALCE 数据集和 NASA 数据集的 SOH 估计效果的评价指标。可以观察到,6 个电池的 SOH 估计值的 MAPE 均小于 2.3%,RMSE 均小于 0.023,MAE

也小于 0.014, R^2 均保持在 0.97 以上,进一步证明了所提方法的高性能。上述通过将 PINN 模型应用在 CALCE 数据集,NASA 数据集上进行模型泛化性能分析,表明了所提模型适用于不同电极材料、复杂工况下电池的 SOH 估计问题且效果比较好。

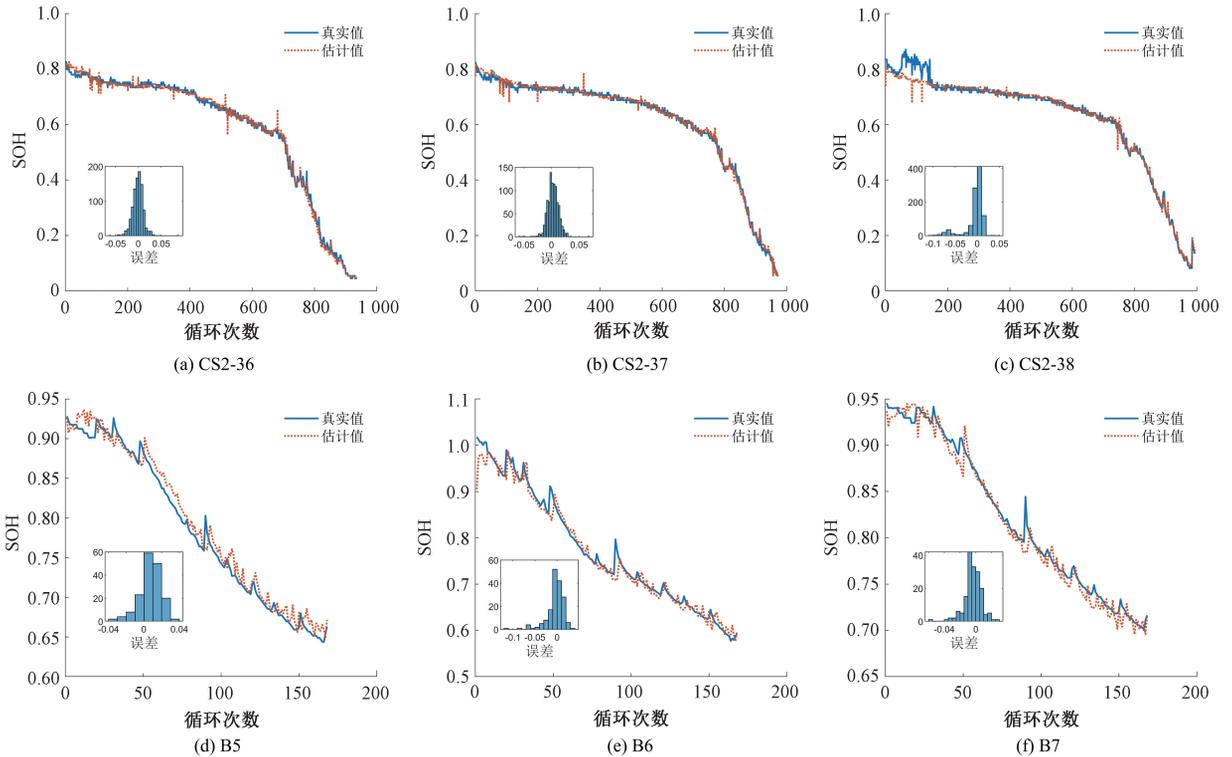


图 7 CALCE 电池和 NASA 电池的 SOH 估计结果。插图表示误差分布

Fig. 7 The SOH estimation results for CALCE batteries and NASA batteries. Illustration shows the distribution of errors

表 4 不同电池数据集 SOH 估计结果的评价指标

Table 4 Evaluation indicators for SOH estimation results of different battery datasets

电池编号	MAPE/%	RMSE	MAE	R^2
CS2-36	2.245 9	0.011 8	0.008 8	0.997 1
CS2-37	1.807 7	0.010 7	0.008 1	0.996 5
CS2-38	2.151 1	0.022 2	0.012 4	0.985 9
B5	1.480 8	0.014 2	0.011 6	0.977 7
B6	1.686 8	0.020 5	0.013 4	0.973 4
B7	1.032 7	0.011 6	0.008 5	0.979 1

5 结论

针对锂电池 SOH 估计的机理模型方法过于复杂、数据驱动方法依赖于大量数据,本文提出了一种基于 INFO-PINN 模型的锂电池 SOH 估计方法。该方法利用两个前馈神经网络去逼近简化的机理模型以建立健康特征与 SOH 的关系,在适量电压数据下就能较好地实现

SOH 的准确估计。方法首先建立电池 SOH 退化过程的偏微分方程模型,然后基于提取的电压特征,利用融合了数据驱动损失和偏微分方程损失的 PINN 去学习该 SOH 退化模型的映射关系,并利用 INFO 算法优化 PINN 网络的超参数,以提高模型的估计精度。最后分别在公开数据集 MIT、CALCE 和 NASA 上进行实验分析。实验结果表明,所提方法不仅对充电策略变化的电池仍然有较高的估计精度,而且对不同电极材料、复杂工况下的 SOH 估计问题仍然有较好的适用性,在 CALCE 数据集和 NASA 数据集上 SOH 估计值的 MAPE 分别小于 2.3% 和 1.7%。虽然本文所提方法准确估计了容量定义的电池 SOH,但容量损失的内在机制:活性材料损失、锂库存损失是无法预知的。后续研究将考虑使用电池的开路电压曲线推测活性材料损失、锂库存损失等电池内部降解参数以优化电池设计。

参考文献

[1] 赵月荷,庞宗强. 基于无迹卡尔曼滤波的动力电池健

- 康状态估计[J]. 国外电子测量技术, 2022, 41(10): 136-141.
- ZHAO Y H, PENG Z Q. State of health estimation of power batteries based on unscented Kalman filter [J]. Foreign Electronic Measurement Technology, 2022, 41(10): 136-141.
- [2] 贺宁, 杨紫琦, 钱成. 基于非参数模型与粒子滤波的锂电池 SOH 估计[J]. 电子测量与仪器学报, 2024, 38(2): 148-159.
- HE N, YANG Z Q, QIAN CH. SOH estimation of lithium-ion battery based on non-parametric model and particle filter[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(2): 148-159.
- [3] 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.
- [4] 钱伟, 王亚丰, 王晨, 等. 基于 BP 神经网络与 H_{∞} 滤波的锂电池 SoH-SoC 联合估计研究[J]. 仪器仪表学报, 2024, 45(6): 307-319.
- QIAN W, WANG Y F, WANG CH, et al. Joint estimation of SoH-SoC for lithium battery based on BP neural network and H infinity filter[J]. Chinese Journal of Scientific Instrument, 2024, 45(6): 307-319.
- [5] 方斯顿, 刘龙真, 孔赖强, 等. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计[J]. 电力系统自动化, 2024, 48(4): 160-168.
- FANG S D, LIU L ZH, KONG L Q, et al. State-of-health estimation for lithium-ion batteries incorporating indirect health indicators based on bi-directional long short-term memory networks[J]. Automation of Electric Power Systems, 2024, 48(4): 160-168.
- [6] ZHAO M F, GAO X D, CHENG M Y, et al. Estimation of lithium-ion battery health state using MHATTCN network with multi-health indicators inputs[J]. Scientific Reports, 2024, 14(1): 18391-18391.
- [7] 刘旖琦, 雷万钧, 刘茜, 等. 基于双自适应扩展粒子滤波器的锂离子电池状态联合估计[J]. 电工技术学报, 2024, 39(2): 607-616.
- LIU Y Q, LEI W J, LIU Q, et al. Joint state estimation of lithium-ion battery based on dual adaptive extended particle filter[J]. Transactions of China Electrotechnical Society, 2024, 39(2): 607-616.
- [8] 柯学, 洪华伟, 郑鹏, 等. 基于多时间尺度建模自动特征提取和通道注意力机制的锂离子电池健康状态估计[J]. 储能科学与技术, 2024, 13(9): 3059-3071.
- KE X, HONG H W, ZHENG P, et al. Estimating lithium-ion battery health using automatic feature extraction and channel attention mechanisms for multi-timescale modeling [J]. Energy Storage Science and Technology, 2024, 13(9): 3059-3071.
- [9] CHEN S Q, ZHANG Q, WANG F, et al. An electrochemical-thermal-aging effects coupled model for lithium-ion batteries performance simulation and state of health estimation [J]. Applied Thermal Engineering, 2024, 239: 122128.
- [10] 尹康涌, 孙磊, 李浩秒, 等. 基于动态噪声自适应无迹卡尔曼滤波的锂离子电池 SOC 估计[J]. 储能科学与技术, 2024, 13(11): 4065-4077.
- YIN K Y, SUN L, LI H M, et al. SOC estimation of lithium-ion batteries based on dynamic adaptive noise unscented Kalman filter algorithm [J]. Energy Storage Science and Technology, 2024, 13(11): 4065-4077.
- [11] ZHU G R, KONG C, WANG V J, et al. A fractional-order electrochemical lithium-ion batteries model considering electrolyte polarization and aging mechanism for state of health estimation [J]. Journal of Energy Storage, 2023, 72(PE): 108649.
- [12] 戴俊彦, 夏明超, 陈奇芳. 基于双重注意力机制的电池 SOH 估计和 RUL 预测编解码模型[J]. 电力系统自动化, 2023, 47(6): 168-177.
- DAI J Y, XIA M CH, CHEN Q F. Encoding and decoding model of state of health estimation and remaining useful life prediction for batteries based on dual-stage attention mechanism [J]. Automation of Electric Power Systems, 2023, 47(6): 168-177.
- [13] AI W L, WU B, MARTÍNEZ-PAÑEDA E. A coupled phase field formulation for modelling fatigue cracking in lithium-ion battery electrode particles [J]. Journal of Power Sources, 2022, 544: 231805.
- [14] YANG B W, WANG D F, ZHANG B, et al. Aging diagnosis-oriented three-scale impedance model of lithium-ion battery inspired by and reflecting morphological evolution [J]. Journal of Energy Storage, 2023, 59: 106357.
- [15] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J]. 高电压技术, 2024, 50(3): 1182-1195.
- XIONG Q, DI ZH G, JI SH CH. Review on health state estimation and life prediction of lithium-ion batteries [J]. High Voltage Engineering, 2024, 50(3): 1182-1195.
- [16] 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.
- 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.

- [17] 李鹏,葛儒哲,董存,等. 基于转置 Transformer 模型的电化学储能自适应 SOH 估计方法[J/OL]. 高电压技术,1-10.
LI P, GE R ZH, DONG C, et al. Adaptive SOH estimation method based on the transpose transformer model for electrochemical energy storage [J/OL]. High Voltage Engineering, 1-10.
- [18] FAN G, LI J, SUN Z, et al. Battery capacity estimation based on a co-learning framework with few-labeled and noisy data [J]. Journal of Power Sources, 2024, 600:234263.
- [19] MURATAHAN A, BALAJI C G, ABRAHAM A, et al. Perspective: Combining physics and machine learning to predict battery lifetime [J]. Journal of The Electrochemical Society, 2021, 168(3):030525.
- [20] RAISSI M, KARNIADAKIS E G. Hidden physics models: Machine learning of nonlinear partial differential equations [J]. Journal of Computational Physics, 2018, 357:125-141.
- [21] MAZIAR R, ALIREZA Y, EM G K. Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations [J]. Science (New York, N. Y.), 2020, 367(6481):1026-1030.
- [22] SEVERSON A K, ATTIA M P, 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



谢国民, 1991 年于辽宁工业大学获得学士学位, 2003 年于辽宁工程技术大学获得硕士学位, 2012 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学教授, 主要研究方向为电池健康管理、电力系统信息检测与故障诊断。

E-mail: lngdxgm@163.com

Xie Guomin received his B. Sc. degree from Liaoning University of Technology in 1991, M. Sc. degree from Liaoning Technical University in 2003, and Ph. D. degree from Liaoning Technical University in 2012, respectively. Now he is a professor in Liaoning Technical University. His main research interests include battery health management, power system information detection and fault diagnosis.



刘澳(通信作者), 2023 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为电池健康管理。

E-mail: 15566702580@163.com

Liu Ao (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2023. Now he is a M. Sc. candidate at Liaoning Technical University. His main research interest includes battery health management.