

DOI:10.19651/j.cnki.emt.2417623

基于弛豫电压曲线的磷酸铁锂电池模组 SOH 评估

陈鑫¹ 马慧敏² 郄晶晶² 郭志鹏¹ 廖强强¹

(1. 上海电力大学上海市电力材料防护与新材料重点实验室 上海 200090;

2. 北京大学鄂尔多斯能源研究院 鄂尔多斯 017000)

摘要: 电池健康状态(SOH)的评估是电池系统的关键技术之一,其准确性对电池系统的安全运行至关重要。弛豫电压曲线含有丰富的电池信息,而且弛豫时间短,适用于非恒定工况下的电池健康状态评估。本文利用弛豫电压曲线来评估磷酸铁锂电池模组的健康状态。首先,建立了基于时间常数与弛豫时间线性相关的磷酸铁锂(LFP)电池模组的弛豫电压模型,并采用粒子群优化(PSO)算法对弛豫电压曲线参数辨识,提取健康因子。其次,开发了基于鹈鹕算法(POA)优化的卷积神经网络(CNN)和双向长短期记忆网络(BiLSTM)的混合模型,用来评估电池的 SOH。研究表明,无论是采用 1/2 C 倍率还是 1 C 倍率充放电获得的弛豫电压曲线,经过 PSO 算法参数辨识得到的变时间常数电压值与真实弛豫电压值的相对误差(RE)均不超过 $\pm 0.12\%$,表明 PSO 方法对不同倍率下的弛豫电压具有良好的参数辨识效果。采用 1/2 C 倍率充放电后的弛豫电压曲线,在训练集低至 5%的情况下,测试集利用 POA-CNN-BiLSTM 模型得到的 SOH 评估相对误差仍不超过 $\pm 1.2\%$;而在 1 C 充放电倍率下,训练集低至 5%时,测试集利用 POA-CNN-BiLSTM 模型得到的 SOH 评估相对误差仍不超过 $\pm 1.6\%$,表明 POA-CNN-BiLSTM 模型评估电池 SOH 具有较高的精度。

关键词: 健康状态;参数辨识;电池模组;鹈鹕算法;卷积神经网络;双向长短期记忆网络

中图分类号: TN702 **文献标识码:** A **国家标准学科分类代码:** 510

The state of health assessment of lithium iron phosphate battery module based on relaxation voltage curves

Chen Xin¹ Ma Huimin² Qie Jingjing² Guo Zhipeng¹ Liao Qiangqiang¹

(1. Shanghai Key Laboratory of Materials Protection and Advanced Materials in Electric Power, Shanghai University of Electric Power, Shanghai 200090, China; 2. Ordos Research Institute of Energy, Peiking University, Ordos 017000, China)

Abstract: The assessment of state of health (SOH) of batteries is one of the key technologies in battery systems, and its accuracy is crucial for the safe operation of battery systems. The relaxation voltage curve contains rich battery information and has a short relaxation time, making it suitable for evaluating the state of health of batteries under non constant operating conditions. This article uses the relaxation voltage curve to evaluate the state of health of lithium iron phosphate battery modules. Firstly, a relaxation voltage model for lithium iron phosphate (LFP) battery modules based on linear correlation between time constant and relaxation time was established, and particle swarm optimization (PSO) algorithm was used to identify the parameters of the relaxation voltage curve and extract health factors. Secondly, a hybrid model of convolutional neural networks (CNN) and bidirectional long short-term memory (BiLSTM) optimized based on pelican optimization algorithm (POA) was developed to evaluate the SOH of batteries. The research results show that regardless of whether the relaxation voltage curve is obtained by charging and discharging at 1/2 C rate or 1 C rate, the relative error (RE) between the variable time constant voltage value identified by PSO algorithm parameters and the true relaxation voltage value does not exceed $\pm 0.12\%$, indicating that PSO method has good parameter identification effect on relaxation voltage at different rates. Using the relaxation voltage curve after charging and discharging at a rate of 1/2 C, the relative error of SOH evaluation obtained using the POA-CNN-BiLSTM model in the test set still does not exceed $\pm 1.2\%$ even when the training set is as low as 5%. At a charge discharge rate of 1 C, when the training set was as low as 5%, the relative error of SOH evaluation obtained

using the POA-CNN-BiLSTM model in the test set still did not exceed $\pm 1.5\%$, indicating that the POA-CNN-BiLSTM model has high accuracy in evaluating battery SOH.

Keywords: state of health; parameter identification; battery module; pelican optimization algorithm; convolutional neural networks; bidirectional long short-term memory

0 引 言

锂离子电池以其高能量密度和超长寿命著称,广泛应用于新能源汽车、储能电站领域。电池容量随着老化的增加而降低,这主要是由于在充放电过程中活性物质和锂离子的损失造成的^[1]。由于电池老化速率不同,造成电池之间的不一致性逐渐凸显。然而,电池的衰减是一个缓慢的过程,电池系统安全运行的关键之一为电池健康状态(state of health, SOH)的评估^[2]。由于单体电池之间存在差异,模组的一致性评估需要综合考虑多个参数的变化,这使得评估过程更加复杂和困难。目前关于电池单体 SOH 评估的研究有很多,例如董明等^[3]对锂电池的电化学阻抗谱的弛豫时间进行了分析,得到了锂电池 SOH 的健康特征之一即特征频率,提出一种关于电化学阻抗谱锂电池 SOH 估计方法。刘少卿等^[4]提出了一种基于 TCN 和 BiGRU 相结合的电池 SOH 评估方法。利用 TCN 模型处理长序列依赖数据并开展特征提取,通过 BiGRU 模型进行历史数据特征建模并对数据退化趋势进行估计,最终实现对锂离子电池 SOH 的精确评估。除了上述基于电池阻抗和容量的 SOH 评估方法外,近年来已经有文献关注到利用电池充放电后的静置过程即弛豫阶段来评估电池 SOH 的新方法。Qian 等^[5]建立了二阶等效电路模型,模拟了电压弛豫的瞬态行为,揭示了动态过程的关键参数。建模方法的基本思想仍然是基于等效电路模型,为了准确拟合弛豫电压曲线弛豫过程的等效电路模型由多个电阻-电容并联链路组成^[6]。Tang 等^[7]将短时弛豫电压序列输入到自动编码器中进行无监督预训练。通过这种自动编码过程,编码器在相同的测试条件下获得了对未标记弛豫电压的特征学习能力。但是自编码器学习到的特征通常难以解释,这不利于对特征进行深入了解且自编码器对数据分布敏感,如果数据分布不均匀,可能会影响模型的性能。毛琦等^[8]在基于粒子群优化(particle swarm optimization, PSO)算法的锂电池模型参数辨识一文中,基于戴维南电池模型,采用 PSO 算法进行离线参数辨识。从毛琦等的研究中可以看出 PSO 算法是一种高效并且简单的算法,在平衡全局优化能力和局部优化能力方面具有显著的优势。王渴心等^[9]在针对极限学习机模型中超参数寻优问题,采用鹈鹕算法(pelican optimization algorithm, POA)进行解决。最后在 NASA 电池数据集上进行试验分析,并与其他经典超参数寻优算法进行了比较。实验结果表明 POA 方法能够实现 SOH 的准确估计,具有较高的估计准确度,估计误差稳定在 2% 以内。关于电池单体

SOH 评估的研究有很多,但对于电池模组 SOH 评估的研究较少,这是因为一般情况下电芯通过焊接形成模组,模组通过铆接的形式形成电池包^[6],采用电池管理系统对循环老化的电池进行数据采集包含每个电芯的测试数据,对电池管理系统的存储要求较高,并且,由于单体电池之间存在差异,模组的一致性评估需要综合考虑多个参数的变化,这对模组数据采集也有较高要求。这使得电池 SOH 评估过程更加复杂和困难。但在实际生活中,无论是储能电站还是电动汽车上应用的都是电池模组,因此,研究电池模组比研究电池单体更具有实际意义。

本文提出了一种基于磷酸铁锂(LiFePO_4 , LFP)电池模组充放电弛豫阶段电压数据,利用 PSO 算法辨识弛豫电压曲线提取健康因子,最后综合考虑 POA 算法的寻优能力、卷积神经网络(convolutional neural networks, CNN)从原始数据提取特征的能力和双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)向前向后的传播能力,开发了 POA 优化 CNN 和 BiLSTM 的混合模型数据驱动的方法,因为与基于模型的方法相比,数据驱动的方法实现起来更简单,并且在实践中更容易获得所使用的健康因子,具有更大的实际应用前景。

1 方 法

1.1 实验对象

以天津比克的 LFP 电池模组为研究对象,此模组以 15 并 4 串(15P4S)的方式成组,额定电压和额定容量分别为 12.8 V 和 40 Ah。图 1 所示为 15P4S 模块电池内部结构图。




图 1 15P4S 模块电池内部结构


Fig. 1 Internal structure of 15P4S module battery

1.2 实验方法


模组容量校准和循环老化测试使用 Bitrode FTV1-300-100 型电池模组测试系统(美国)在 $25^\circ\text{C} \pm 1^\circ\text{C}$ 下进行^[2]。用 1/3 C 倍率的恒流(constant current, CC)校准电

池模组的容量,达到 15P4S 的模组上限电压 14.6 V 或电池电压最高单体电压 ≥ 3.75 V 后转为恒压(constant voltage, CV)充电,直到下限截止电流 $\leq 1/30$ C 倍率为止。静置 30 min 后,施加 $1/3$ C 倍率的 CC,将模组放电至 15P4S 的下限模组电压 10.8 V 或单个电池电压 2.5 V。电池循环老化方案与校准方案基本一致,只是将充放电倍率设置为 $1/2$ C 倍率或 1 C 倍率。每 100 次老化循环后进行一次容量校准。当老化模组的 SOH 低于 60% 时,循环结束。数据采样频率为 1 min。C 倍率的定义是电池在规定时间内放电其额定容量所需电流值,等于充电或放电电流与额定容量的比值^[10]。15P4S 电池模组的额定容量为 40 Ah,当使用的充放电电流为 20 A 时,充放电倍率为 $1/2$ C 倍率。

图 2 为 LFP 电池模组不同倍率循环老化曲线图,展示了 LFP 电池模组的循环老化测试方案,循环老化倍率分别为 $1/2$ C 倍率和 1 C 倍率。



(a) 1 C 倍率循环老化电流-电压-时间曲线
(a) 1 C rate cyclic aging current voltage time curve



(b) $1/2$ C 倍率循环老化电流-电压-时间曲线
(b) $1/2$ C rate cyclic aging current voltage time curve

图 2 LFP 电池模组不同倍率循环老化曲线

Fig. 2 LFP battery module cyclic aging curves at different rates

2 方 法

2.1 SOH 和 SOC 的定义

SOH 用来表示电池的 SOH 或劣化程度,电池荷电状态(state of charge, SOC)定义是电池的可用容量占最大可用容量的比例。本文从容量角度来定义 SOH 和 SOC,如式(1)和(2)所示。


$$SOH = \frac{Q_{pre-max}}{Q_{rated}} 100\% \quad (1)$$

$$SOC = \frac{Q_{pre}}{Q_{pre-max}} 100\% \quad (2)$$


式中: Q_{rated} 定义为新电池的额定容量, $Q_{pre-max}$ 定义为循环老化后电池的最大的可用容量, Q_{pre} 定义为循环老化后电池目前的荷电容量。

2.2 弛豫电压

图 3 为 LFP 电池模组不同倍率下充放电后的弛豫电压曲线。电池的开路电压(open circuit voltage, OCV)定义为电池正、负极间的电位差,主要由 SOC 决定。不同正负极材料的电池有其特定的 SOC-OCV 曲线。随着电池的老化,弛豫电压曲线的形状也会发生变化。这种现象的机制是复杂的,可能的解释包括正负电极上活性物质的损失,正负电极材料的结构变化,或循环锂离子量的损失。



(a) 不同倍率下充电后的弛豫电压曲线
(a) Relaxation voltage curves after charging at different rates



(b) 不同倍率下放电后的弛豫电压曲线
(b) Relaxation voltage curves after discharging at different rates

图 3 LFP 电池模组不同倍率下充放电后的弛豫电压曲线

Fig. 3 Relaxation voltage curve of LFP battery module after charging and discharging at different rates

弛豫电压曲线的分析一般以时间常数为基础,用时间常数表示端电压的恢复速度。扩散过电位是由锂离子从电极表面向内部扩散过程产生的。从图 3 可以看出,动态电压变化过程即扩散过程,贯穿大部分弛豫期,释放过程持续时间较长。因此,这一过程是弛豫电压研究的关键^[11]。由此分析,弛豫电压 U_{RLX} 可表示为:

$$U_{RLX} = U_{L,t} - U_{ocv} \quad (3)$$

式中: U_{ocv} 为模组电池开路电压, $U_{L,t}$ 为 t 时刻时, 电池模组端电压。

在其他文献中通常将 τ 定义为时间常数, 表示释放过程速率的常数, 但在本研究中, 考虑到 τ 是一个随时间变化的变量, 故称其为变时间常数, 由式(4)可知, 不同开路时间下 τ 的表达式为:

$$\tau = \frac{1}{\ln U_{ocv} - \ln U_{ocv-1}} \quad (4)$$

已知 U_{ocv} , 根据弛豫电压曲线和式(4), 可以得到不同弛豫时间的 τ 。

图 4 展示了 LFP 电池模组在不同倍率充放电后弛豫

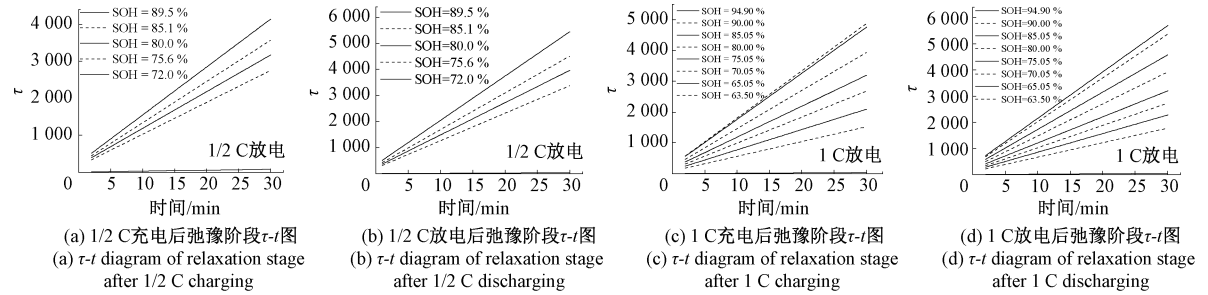


图 4 LFP 电池模组在不同倍率充放电后弛豫阶段的时间常数和时间

Fig. 4 Time constants and time plots of relaxation stages of LFP battery modules after charging and discharging at different rates

2.3 参数辨识方法

文献[12]证明, PSO 算法在模型参数识别方面的综合性能优于其他基于群的方法。因此, 粒子群算法被视为本研究中全局优化方法的代表算法, 用于识别模型参数。

在 PSO 中, 每个粒子可以根据自己的个体最优解和群体的全局最优解不断更新自己的速度和位置[12]。定义粒子总数为 n , 则第 i 个粒子在 D 维空间中的位置 ϑ_i 和速度 v_i 为:

$$\begin{cases} \vartheta_i = (\vartheta_{i1}, \vartheta_{i2}, \dots, \vartheta_{iD}), i = 1, 2, \dots, n \\ v_i = (v_{i1}, v_{i2}, \dots, v_{iD}), i = 1, 2, \dots, n \end{cases} \quad (7)$$

每个粒子的位置和速度更新的公式如式(8)所示。

$$\begin{cases} v_i^{k+1} = \omega \cdot v_i^k + c_1 \cdot \zeta_k (P_{i,j}^k - \vartheta_i^k) + c_2 \cdot \gamma_k (P_g^k - \vartheta_i^k) \\ \vartheta_i^{k+1} = \vartheta_i^k + v_i^{k+1} \end{cases} \quad (8)$$

式中: P_j 定义为个体的最优解; P_g 定义为群体的全局最优解; ζ 和 γ 分别是 $0 \sim 1$ 的随机数; c_1 与 c_2 定义为学习因子; ω 为惯性系数。

$$F_k = |U_{t,k} - \widehat{U}_{t,k}| \quad (9)$$

式中: $U_{t,k}$ 和 $|\widehat{U}_{t,k}|$ 分别为实测端电压和评估端电压。粒子群优化算法流程如图 5 所示。

2.4 LFP 电池模组 SOH 评估

1) 卷积神经网络 (convolutional neural networks, CNN)

CNN 能够对从最简单到最复杂的信息进行分类。它

阶段的时间常数和时间, 在不同 SOH 下, 时间常数和时间的有良好的线性关系。从图 4 可以看出, 在不同的 SOH 下, 时间常数随着时间的变化趋势是线性的, 故本文提出采用线性的函数关系表达式来表示 τ 的变化, 得到了模组电池的弛豫时间与弛豫电压曲线模型, 由式(5)和式(6)表示。

$$U_{L,t} = U_{ocv} - (U_{ocv} - U_{L,t-1})e^{-\frac{t}{\tau}} \quad (5)$$

$$\tau = at + b \quad (6)$$

其中, a, b 为表征弛豫时间模型 $\tau-t$ 曲线上的截距和斜率。

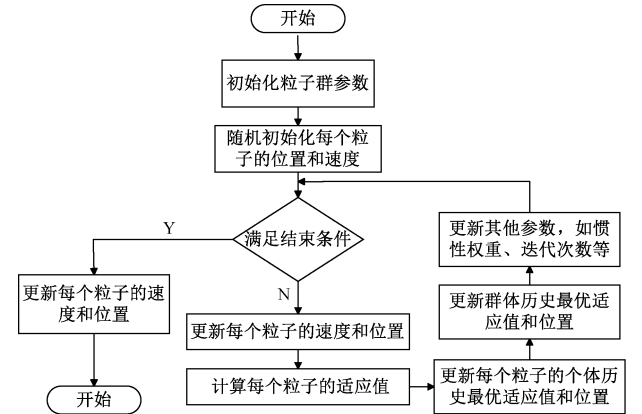


图 5 粒子群算法流程


Fig. 5 Particle swarm optimization algorithm flowchart

们由多层神经元堆栈组成, 具有几个可调参数的数学函数, 用于预处理数据信息, 并从原始数据中提取特征。CNN 的评估精度一般优于常用的机器学习的方法。文献[13]提出 CNN 的训练过程。

2) 双向长短期记忆 (bidirectional long short-term memory, BiLSTM) 网络

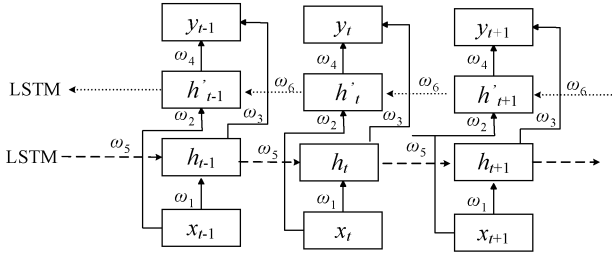
文献[14]提出 LSTM 网络通过门控制信息记住长期信息, 在 LSTM 基础上建立 BiLSTM 神经网络模型可有效解决 CNN 因为数据量增大、时间间隔增长引起的梯度消失或梯度爆炸等缺陷[14], 最大程度地提取特征之间的内在相关性, 更好地提取弛豫电压曲线数据的双向时序特

征。BiLSTM 包括 3 个门控单元,即输入门(i_t)、输出门(o_t)和遗忘门(f_t)^[14]。其结构如图 6 所示。输入门负责在当前时刻更新序列信息,遗忘门负责 CNN 的结构。



(a) LSTM网络结构

(a) LSTM network architecture



(b) BiLSTM网络结构

(b) BiLSTM network architecture

图 6 算法网络结构

Fig. 6 algorithm network structure

对于 BiLSTM 网络, t 时刻的输出 y_t 由 3 部分组成,即 t 时刻的输入 x_t 、前向 LSTM 网络前一刻的输出状态 h_{t-1} 、后向 LSTM 网络后一刻的输出状态 h'_{t+1} 。 h_t 、 h'_t 、 y_t 的实现公式分别为:

$$h_t = z_1(\omega_1 x_t + \omega_5 h_{t-1}) \quad (10)$$

$$h'_t = z_2(\omega_2 x_t + \omega_6 h'_{t+1}) \quad (11)$$

$$y_t = z_3(\omega_3 h_t + \omega_4 h'_t) \quad (12)$$

式中: ω_i ($i=1,2,\dots,6$) 为各层相应的权重; z_i ($i=1,2,3$) 为不同层的激活函数。

然而 BiLSTM 网络难以挖掘数据的空间特征,考虑到 CNN 较强的空间特征提取能力,文献[15-17]提出了 CNN-BiLSTM 模型,因为 CNN-BiLSTM 模型的误差、均方根误差均低于 CNN、BiLSTM 和 LSTM 模型^[15]。但是 CNN-BiLSTM 模型评估的精度主要取决于 BiLSTM 网络的参数选取,参数选取的方法通常采用多次尝试法,这导致了模型预测的效率低^[15-17]。

3) 鹈鹕优化算法 (pelican optimization algorithm, POA)

POA 通过随机生成猎物来搜索猎物,增强了其全局搜索能力。猎物的随机生成解决了其他算法过度依赖变异系数逃避局部最优的问题^[13]。POA 的寻优步骤如下:

(1) 初始化参数:设置待优化自变量的空间维度 S 。 C_{\max} 表示最大迭代次数, P 表示总体大小;

(2) 构造适应度函数,更新初始的鹈鹕种群最优位置 $X_{\text{pest}} = X(0)$,得到目前位置的适应度为 $F_{\text{best}} = F(X_{\text{pest}})$;

(3) 在探索阶段,鹈鹕种群在水面上巡逻猎物,随机产生猎物位置并不断更新鹈鹕种群位置^[13]。

$$x_{i,j}^{Q_1} = \begin{cases} x_{i,j} + \text{rand} \cdot (Q_j - I \cdot x_{i,j}), & F_Q < F_i \\ x_{i,j} + \text{rand} \cdot (x_{i,j} - Q_j), & F_Q \geq F_i \end{cases} \quad (13)$$

式中:更新后的位置记为 $x_{i,j}^{Q_1}$,表示第 j 维在第 i 代中的位置。 Q_j 表示猎物在第 j 维上的位置, F_Q 表示与猎物相关的目标函数的值, I 表示一个随机数,可以是 1 也可以是 2, I 决定了个体是否向新的探索区域移动更大的距离。因此,POA 彻底搜索解空间的能力受到参数 I 的影响。一旦鹈鹕完成对猎物的搜寻,就会将新位置的适合度与旧位置进行比较,并将最优位置更新为适合度最低的位置。通过这种方式,鹈鹕向最佳区域移动。

$$x_i = \begin{cases} x_i^{Q_1}, & F_i^{Q_1} < F_i \\ x_i, & F_i^{Q_1} \geq F_i \end{cases} \quad (14)$$

式中: $x_i^{Q_1}$ 表示第 i 只鹈鹕的更新状态, $F_i^{Q_1}$ 表示寻优阶段获得的目标函数值。

(4) 在发育阶段,鹈鹕的翅膀会展开,鱼会被驱赶到鹈鹕的喉袋中,其数学模型为:

$$x_{i,j}^{Q_2} = x_{i,j} + R \cdot \left(1 - \frac{t}{C_{\max}}\right) \cdot (2 \cdot \text{rand}^{-1}) \cdot x_{i,j} \quad (15)$$

式中: $x_{i,j}^{Q_2}$ 表示基于发育阶段的更新位置,第 i 代在第 j 维中的位置。 R 是一个等于 0.2 的常数, $R \cdot \left(1 - \frac{t}{C_{\max}}\right)$ 表示 $x_{i,j}$ 的邻域半径,其中 $\frac{t}{C_{\max}}$ 表示迭代过程。

在完成发育阶段后,将新位置的适应度与旧位置进行比较,并将此时的最佳位置更新为适应度最低的位置。

$$x_i = \begin{cases} x_i^{Q_2}, & F_i^{Q_2} < F_i \\ x_i, & F_i^{Q_2} \geq F_i \end{cases} \quad (16)$$

式中: $x_i^{Q_2}$ 表示第 i 代在发育阶段的位置, $F_i^{Q_2}$ 表示鹈鹕的适应度。

(5) 将鹈鹕的全局最优位置更新为 $X_{\text{gbest}} = X(1)$,当前位置的全局最优适应度更新为 $F_{\text{gbest}} = F(X_{\text{gbest}})$ 。然后,重复步骤(3)和(4),直到达到最大迭代次数得到算法的最优解^[18]。

POA 通过随机生成猎物来搜索猎物,增强了其全局搜索能力。能快速优化 BiLSTM 网络的相关参数,为了提高电池 SOH 评估精度,本文综合考虑 POA 的寻优能力,CNN 从原始数据提取特征的能力和 BiLSTM 向前向后的传播能力,开发了 POA 优化 CNN 和 BiLSTM 的混合模型数据驱动的方法。

模型选择相对误差 (relative error, RE) 作为适应度函数,迭代运行 100 次,选择最优参数作为寻优结果,其评估

步骤如图 7 所示。

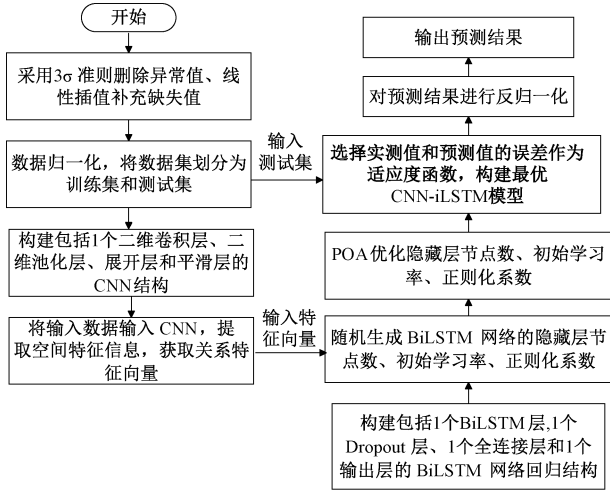


图 7 POA-CNN-BiLSTM 评估模型

Fig. 7 POA-CNN-BiLSTM evaluation model

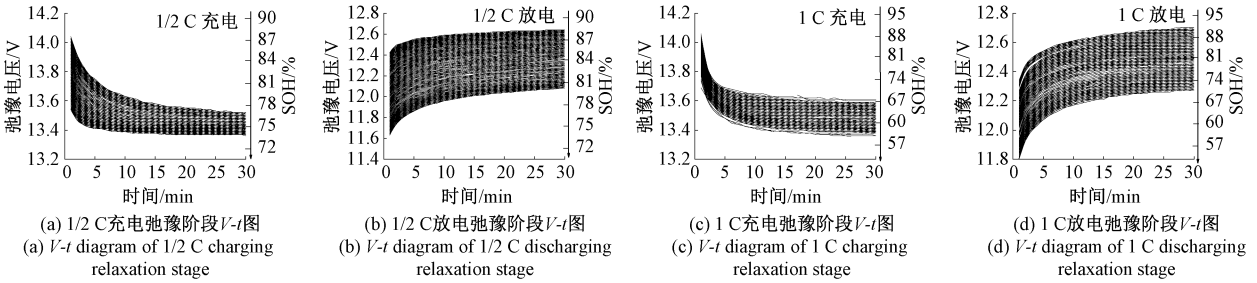


图 8 LFP 电池模组不同倍率下充放电弛豫阶段弛豫电压时间

Fig. 8 Relaxation voltage time chart of LFP battery module during charge and discharge relaxation stages at different rates

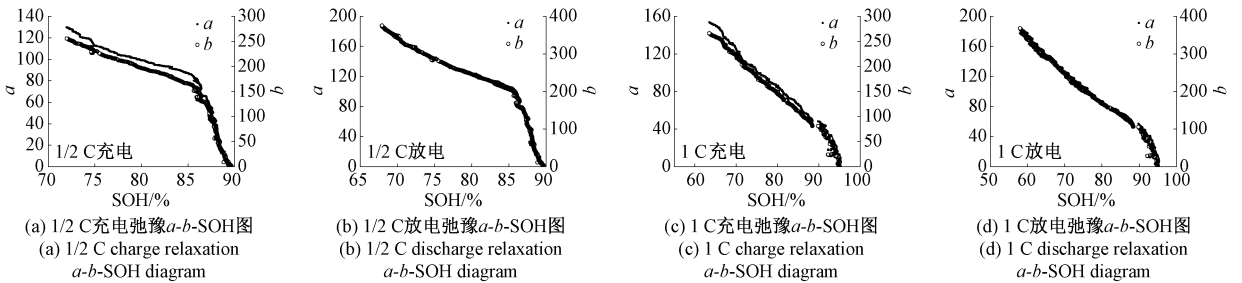


图 9 LFP 电池模组在不同倍率充放电后弛豫时间模型的斜率 a 和截距 b 与 SOH 的关系

Fig. 9 The relationship between the slope a and intercept b of the relaxation time model of LFP battery module after different rates of charge and discharge and SOH

出变时间常数电压值,根据定时间常数电压值和变时间常数电压值可以绘制出图 11,LFP 电池模组在不同倍率充放电后弛豫阶段真实电压值与定时间常数电压值和变时间常数电压值曲线图。利用式(17)求得在 1/2 C 充放电倍率下,采用变时间常数的弛豫时间模型估计的弛豫电压 RE 不超过 $\pm 0.1\%$,在 1 C 充放电倍率下,采用变时间常数的弛豫时间模型估计的弛豫电压 RE_V 不超过 $\pm 0.12\%$ 。由此可以看出变时间常数电压与真实电压拟合精度较高,定时间常数电压与真实电压拟合精度较低。因此,变时间常

3 结果与讨论

3.1 基于弛豫电压曲线的健康因子提取

图 8 为 LFP 电池模组不同倍率下充放电弛豫阶段弛豫电压时间图。从图 8 可以看出,弛豫电压曲线具有极强的非线性特征。

图 9 为 LFP 电池模组在不同倍率充放电后弛豫时间模型的斜率 a 和截距 b 与 SOH 的关系图,PSO 算法参数辨识得到的弛豫时间模型的斜率和截距,随 SOH 变化,虽然采用不同的老化机制,但斜率和截距在不同的充放电倍率下体现了相同的趋势。

图 10 为 LFP 电池模组在不同倍率充放电后弛豫阶段真实弛豫电压值与定时间常数电压值和变时间常数电压值曲线图和误差图。将弛豫时间直接代入式(5)可以求出定时间常数电压值,利用 PSO 算法得到的 a 和 b ,将 a 和 b 代入式(6)可以求出变时间常数 τ ,将 τ 代入式(5)可以求

数法可以较好地反映出弛豫电压的变化情况。

$$RE_V = \frac{V_{\text{估计}} - V_{\text{真实}}}{V_{\text{真实}}} \times 100\% \quad (17)$$

式中: RE_V 为估计电压值与真实电压值的相对误差, $V_{\text{估计}}$ 为估计电压值, $V_{\text{真实}}$ 为真实电压值。

3.2 SOH 评估

将 PSO 算法参数辨识得到的弛豫时间模型的截距和斜率作为健康因子,和弛豫电压曲线的开路电压一起作为 POA-CNN-BiLSTM 算法的输入。首先对数据集进行归一

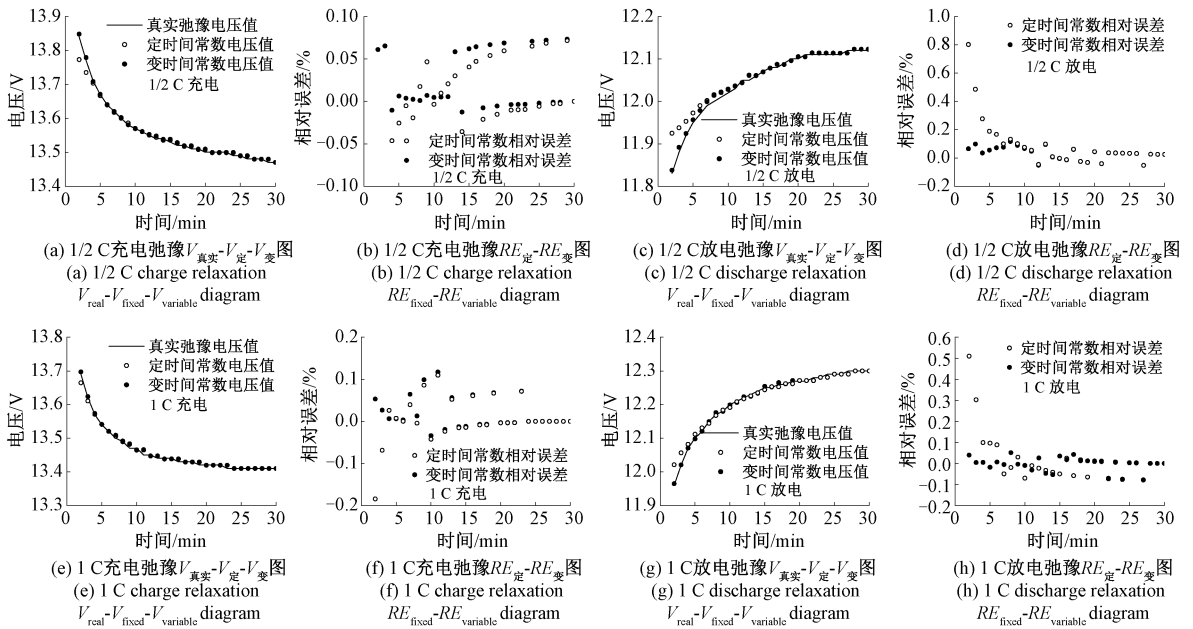
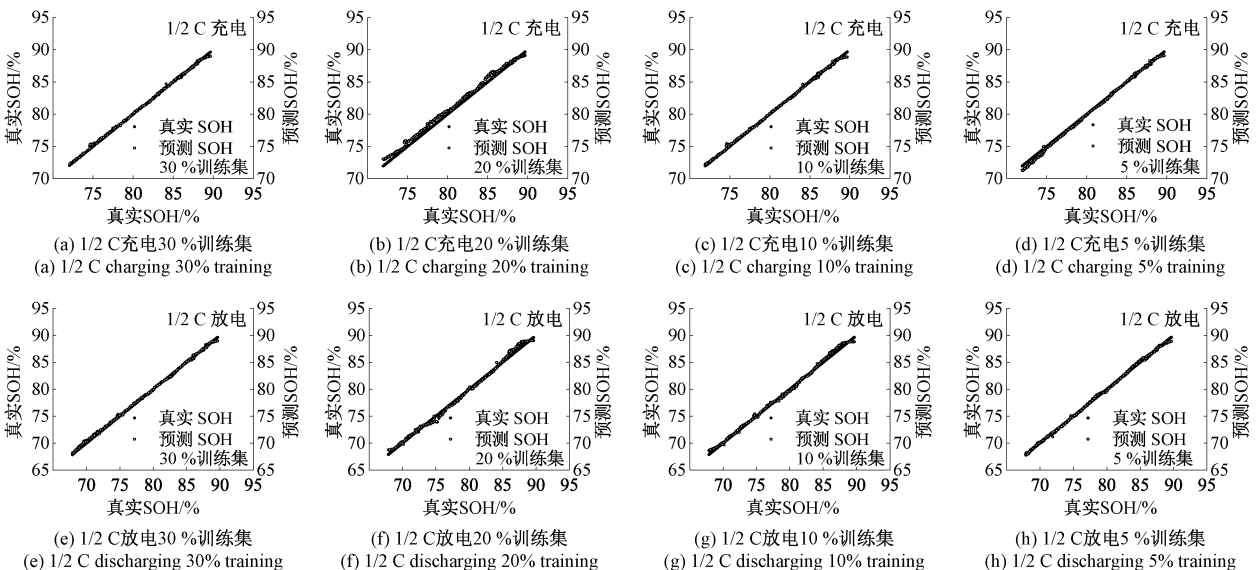


图 10 LFP 电池模组在不同倍率充放电后弛豫阶段真实弛豫电压值与定时间常数电压值和变时间常数电压值曲线和误差
 Fig. 10 The curve and error plot of the true relaxation voltage value, fixed time constant voltage value, and variable time constant voltage value during the relaxation stage of LFP battery module after charging and discharging at different rates

化,划分训练集和测试集,将模型训练集划分为 30%、20%、10%和 5%作为输入,首先进行 CNN 特征提取,构建卷积神经网络结构,将训练数据集数据输入 CNN。接下来构建 BiLSTM 网络回归结构,随机生成 BiLSTM 网络的隐藏层节点数、初始学习率、正则化系数。将 CNN 中提取的关系特征向量输入到 BiLSTM,采用 POA 优化 CNN-BiLSTM 模型参数,选择 SOH 真实值和评估值的 RE 作为适应度函数,得到最优 CNN-BiLSTM 评估模型。将测试集数据输入到 PSO-CNN-BiLSTM 评估模型,算法迭代次数为 100 次,选择最优的参数作为寻优结果。参数优化结果为模

型节点数为 12,学习率为 4×10^{-3} ,正则化系数为 1×10^{-4} 。

图 11 为 LFP 电池模组在不同倍率充放电后不同训练集的真实 SOH 与评估 SOH 图。图 11 采用双纵轴单横轴绘制,左纵轴和横轴为真实 SOH 值,右纵轴为评估 SOH 值,图中实心点和空心点重合度越大,表示真实值越接近评估值。从图 11 中可以看出,LFP 电池模组在充放电倍率为 1/2 C,训练集为 30%、20%、10%和 5%时,真实 SOH 与评估 SOH 高度重合。当充放电倍率为 1 C,训练集分别为 30%、20%、10%和 5%时,真实 SOH 与评估 SOH 也高度重合。



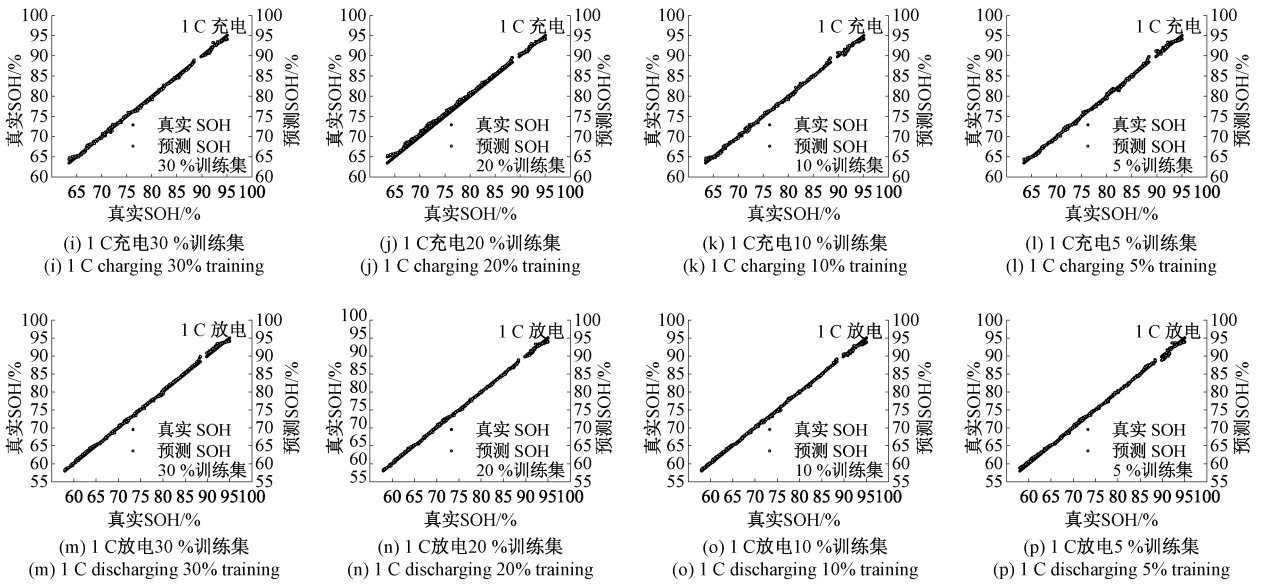


图 11 LFP 电池模组在不同倍率充放电后不同训练集的真实 SOH 与评估 SOH

Fig. 11 Real SOH and evaluation SOH maps of LFP battery modules on different training sets after charging and discharging at different rates

$$RE_{SOH} = \frac{SOH_{估计} - SOH_{真实}}{SOH_{真实}} \times 100\% \quad (18)$$

式中： RE_{SOH} 为估计 SOH 值与真实 SOH 值的相对误差， $SOH_{估计}$ 为估计 SOH 值， $SOH_{真实}$ 为真实 SOH 值。

图 12 为 LFP 电池模组在不同倍率充放电后不同训练集真实 SOH 值与评估 SOH 值误差图。LFP 电池模组根

据式(18)可以求出，在 $1/2 C$ 充放电循环老化倍率下，不同训练集的 RE_{SOH} 均小于 $\pm 1.2\%$ 。在 $1 C$ 充放电循环老化倍率下，不同训练集的 RE_{SOH} 均小于 $\pm 1.6\%$ 。由此可以看出 POA 算法改进 CNN-BiLSTM 评估模型可以很好的评估电池 SOH。

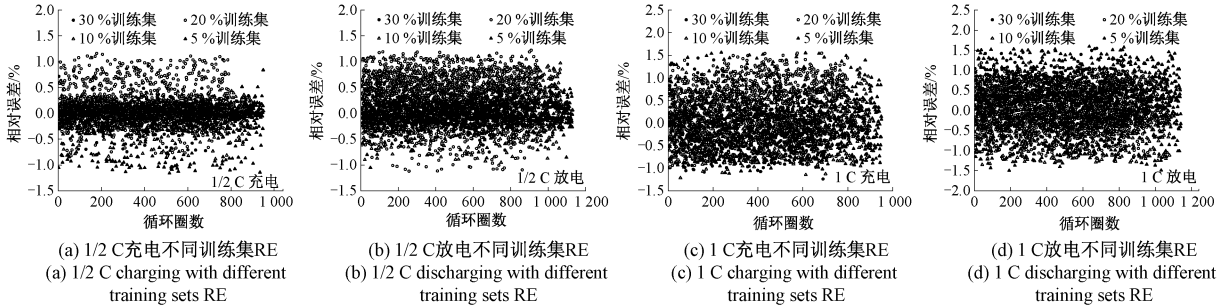


图 12 LFP 电池模组在不同倍率充放电后不同训练集真实 SOH 值与评估 SOH 值相对误差

Fig. 12 Relative error chart of real SOH values and evaluated SOH values of 12 LFP battery modules on different training sets after charging and discharging at different rates

表 1 为训练集为 5% 时不同模型 SOH 评估结果，LFP 电池模组在不同的充放电倍率下，训练集为 5% 时，POA 改进 CNN-BiLSTM 算法的评估精度均高于 CNN-BiLSTM 算法，相较于传统的 CNN-BiLSTM 算法，采用 POA 改进 CNN-BiLSTM 算法在 5% 训练集的相对误差降

低 4% 左右。从图 12 和表 1 的 RE_{SOH} 结果可以看出， $1/2 C$ 倍率充放电比 $1 C$ 倍率充放电时 SOH 评估精度高。这是因为小倍率的充放电电压数据的精细化程度更高，从而 SOH 的评估精度也更高。

表 1 训练集为 5% 时不同模型 RE_{SOH} 评估结果

Table 1 RE_{SOH} evaluation results of different models when the training set is 5%

算法	5% 训练集 RE_{SOH}			
	1/2 C 充电	1/2 C 放电	1 C 充电	1 C 放电
CNN-BiLSTM	-5.12%~4.97%	-5.13%~5.12%	-5.52%~4.87%	-5.66%~4.90%
POA-CNN-BiLSTM	-1.11%~0.84%	-1.05%~0.61%	-1.12%~1.56%	-1.50%~1.59%

图 13 为 LFP 电池模组在不同倍率充放电后不同训练集真实 SOH 值与评估 SOH 值平均绝对误差 (mean absolute error, MAE)。LFP 电池模组根据式(19)可以求出,在 1/2 C 充放电循环老化倍率下,不同训练集的 MAE_{SOH} 均小于 1.1%。在 1 C 充放电循环老化倍率下,不同训练集的 MAE_{SOH} 均小于 1.5%。由此可以看出 POA 算法改进 CNN-BiLSTM 评估模型可以很好的评估电池 SOH。

$$MAE_{SOH} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (19)$$

表 2 训练集为 5% 时不同模型 MAE_{SOH} 评估结果

Table 2 MAE_{SOH} evaluation results of different models when the training set is 5%

算法	5% 训练集 MAE_{SOH}			
	1/2 C 充电	1/2 C 放电	1 C 充电	1 C 放电
CNN-BiLSTM	2%~5.97%	2.13%~6.12%	1.52%~6.87%	3.66%~5.90%
POA-CNN-BiLSTM	0%~0.84%	0%~0.78%	0%~1.38%	0%~1.47%

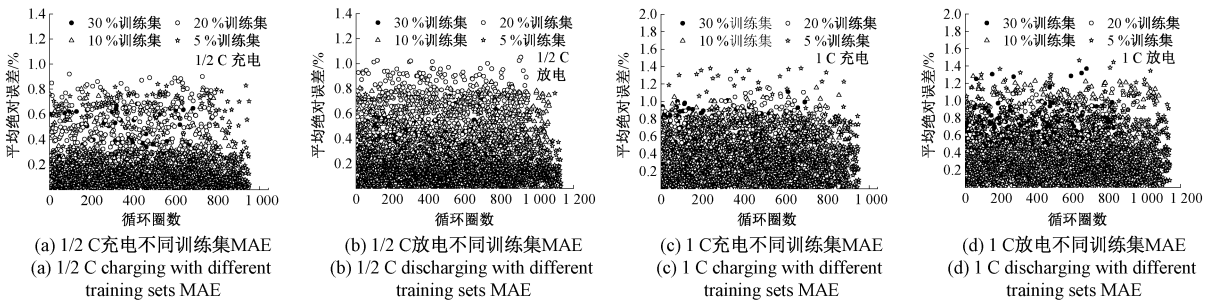


图 13 LFP 电池模组在不同倍率充放电后不同训练集真实 SOH 值与评估 SOH 值平均绝对误差

Fig. 13 Mean absolute error between true SOH values and evaluated SOH values of LFP battery modules on different training sets after charging and discharging at different rates

图 14 为 LFP 电池模组在不同倍率充放电后不同训练集真实 SOH 值与评估 SOH 值均方误差 (mean squared error, MSE)。LFP 电池模组根据式(20)可以求出,在 1/2 C 充放电循环老化倍率下,不同训练集的 MSE_{SOH} 均小于 1.1%。在 1 C 充放电循环老化倍率下,不同训练集的 MSE_{SOH} 均小于 2.2%。由此可以看出 POA 算法改进 CNN-BiLSTM 评估模型可以很好的评估电池 SOH。从

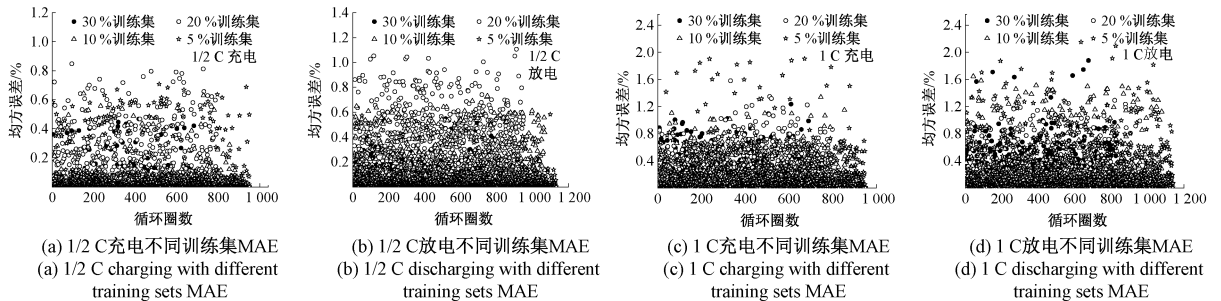


图 14 LFP 电池模组在不同倍率充放电后不同训练集真实 SOH 值与评估 SOH 值均方误差

Fig. 14 Mean square error plot of true SOH values and evaluated SOH values for LFP battery modules on different training sets after charging and discharging at different rates

式中: MAE_{SOH} 为真实 SOH 值与估计 SOH 值绝对误差的平均数, y_i 为真实 SOH 值, \hat{y}_i 为估计 SOH 值。

表 2 为训练集为 5% 时不同模型 MAE_{SOH} 评估结果。LFP 电池模组在不同的充放电倍率下,训练集为 5% 时, POA 改进 CNN-BiLSTM 算法的评估精度均高于 CNN-BiLSTM 算法,相较于传统的 CNN-BiLSTM 算法,采用 POA 改进 CNN-BiLSTM 算法在 5% 训练集的 MAE_{SOH} 降低 4% 左右。从图 13 和表 2 的 MAE_{SOH} 结果可以看出, 1/2 C 倍率充放电比 1 C 倍率充放电时 SOH 评估精度高。

图 14 和表 3 的 MSE_{SOH} 结果可以看出, 1/2 C 倍率充放电比 1 C 倍率充放电时 SOH 评估精度高。

$$MSE_{SOH} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (20)$$

式中: MSE_{SOH} 为真实 SOH 值与估计 SOH 值绝对误差的平均数, y_i 为真实 SOH 值, \hat{y}_i 为估计 SOH 值。

表 3 训练集为 5% 时不同模型 MSE_{SOH} 评估结果Table 3 MSE_{SOH} evaluation results of different models when the training set is 5%

算法	5% 训练集 MSE_{SOH}			
	1/2 C 充电	1/2 C 放电	1 C 充电	1 C 放电
CNN-BiLSTM	2.12%~4.97%	1.13%~5.12%	2.52%~6.87%	1.66%~7.90%
POA-CNN-BiLSTM	0%~0.71%	0%~0.60%	0%~1.91%	0%~2.15%

4 结 论

以 LFP 电池模组充放电后的弛豫电压数据为基础,采用 PSO 参数辨识和 POA-CNN-BiLSTM 模型对不同充放电倍率下的电池 SOH 进行评估,得到以下结论:

在 1/2 C 充放电倍率下,采用变时间常数的弛豫时间模型估计的弛豫电压相对误差为 $\pm 0.1\%$, 小于采用定时间常数的;在 1 C 充放电倍率下,采用变时间常数的弛豫时间模型估计的弛豫电压相对误差为 $\pm 0.12\%$, 小于采用定时间常数的,说明变时间常数的弛豫时间模型估计弛豫电压具有更高的准确性。

采用 POA 优化的 CNN-BiLSTM 混合模型来评估电池 SOH。在 1/2 C 充放电倍率下,采用 POA 优化的 CNN-BiLSTM 混合模型估计的电池 SOH 相对误差为 $\pm 1.2\%$, 小于采用定时间常数的;在 1 C 充放电倍率下,采用 POA 优化的 CNN-BiLSTM 混合模型估计的弛豫电压相对误差为 $\pm 1.6\%$, 小于未采用 POA 算法优化的,说明采用 POA 优化的 CNN-BiLSTM 混合模型估计电池 SOH 具有更高的准确性。

PSO 算法参数辨识得到的弛豫时间模型的截距和斜率作为健康因子,和弛豫电压曲线的开路电压一起作为 POA-CNN-BiLSTM 算法的输入,在不同充放电倍率的 LFP 电池模组上评估电池模组 SOH 均有较高的精度,说明该方法用于评估电池模组 SOH 是可行的。

本方法采用的开路电压是在静置 30 min 后获得的,下一步将考虑静置更短的时间下获得的开路电压作为模型的输入,讨论该方法评估电池模组 SOH 的可行性。本方法采用的变时间常数的弛豫时间模型为线性模型,下一步将考虑非线性的变时间常数的弛豫时间模型作为模型的输入。本文研究了 POA-CNN-BiLSTM 模型在 LFP 电池模组中的 SOH 评估,后续工作中该模型将用在 LFP 单体和三元锂电池的单体和模组,进一步验证该模型的泛化能力和鲁棒性。对于该模型在 LFP 单体和三元锂电池模组和单体的 SOH 评估方面需要做进一步的研究和验证。本模型应用在电池模组充满或者放空情况下,此时电池的 SOC 为 100% 或 0%,对于不同 SOC 下的弛豫电压曲线该模型是否依然适用以及精度如何,需要进一步验证。

参考文献

[1] 张志伟, 郑见杰. 大电流脉冲工况下磷酸铁锂电池衰减机理[J]. 电源技术, 2022, 46(9): 984-987.

ZHANG ZH W, ZHENG J J. Degradation mechanism of LFP lithium ion battery under high current pulse condition [J]. Chinese Journal of Power Sources, 2022, 46(9): 984-987.

[2] 张雅, 蔡永翔, 刘伟, 等. 基于区域容量的锂离子电池健康状态评估[J]. 电子测量技术, 2023, 46(17): 168-174.

ZHANG Y, CAI Y X, LIU W, et al. State of health estimation of lithium-ion batteries based on the regional capacity [J]. Electronic Measurement Technology, 2023, 46(17): 168-174.

[3] 董明, 范文杰, 刘王泽宇, 等. 基于特征频率阻抗的锂离子电池健康状态评估[J]. 中国电机工程学报, 2022, 42(24): 9094-9105.

DONG M, FAN W J, LIU W Z Y, et al. Health assessment of lithium-ion batteries based on characteristic frequency impedance[J]. Proceedings of the CSEE, 2022, 42(24): 9094-9105.

[4] 刘少卿, 李帅, 苗建国, 等. 基于 TCN-BiGU 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-BiGU[J]. Electronic Measurement Technology, 2023, 46(23): 68-76.

[5] QIAN K, HUANG B H, RAN A H, et al. State-of-health (SOH) evaluation on lithium-ion battery by simulating the voltage relaxation curves [J]. Electrochimica Acta, 2019, 303: 183-191.

[6] 骆凡, 黄海宏, 王海欣. 基于电化学阻抗谱的退役动力电池荷电状态和健康状态快速评估[J]. 仪器仪表学报, 2021, 42(9): 172-180.

LUO F, HUANG H H, WANG H X. Rapid prediction of the state of charge and state of health of decommissioned power batteries based on electrochemical impedance spectroscopy[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 172-180.

[7] TANG AI H, XU Y CH, LIU P, et al. Deep learning driven battery voltage-capacity curve prediction utilizing short-term relaxation voltage [J].

- eTransportation, 2024, 22: 100378.
- [8] 毛琦, 祝乔, 徐志杰, 等. 基于粒子群优化算法的锂电池模型参数辨识[J]. 电工技术, 2021, 12: 156-157.
MAO Q, ZHU Q, XU ZH J, et al. Parameter identification of batter model based on the particle swarm optimization[J]. Electric Engineering, 2021, 12: 156-157.
- [9] 王渴心, 周军, 王岩. 基于鹈鹕优化和极限学习机的锂离子电池健康状态估计[J]. 电气应用, 2023, 42(11): 16-25.
WANG K X, ZHOU J, WANG Y. State of health estimation of lithium-ion battery based on Pelican optimization algorithm and Extreme learning machine[J]. Electrotechnical Application, 2023, 42(11): 16-25.
- [10] 陈金宏. LiFePO₄ 正极导电体系及其倍率放电性能研究[D]. 湖南:国防科学技术大学, 2010.
CHEN J H. Study on the conductive system and the rate discharge performance of LiFePO₄ cathode [D]. Hunan: National University of Defense Technology, 2010.
- [11] WANG R Z, LI J F, WANG X Y, et al. Deep learning model for state of health estimation of lithium batteries based on relaxation voltage[J]. Journal of Energy Storage, 2024, 79: 110189.
- [12] ZHANG SH ZH, ZHANG X W. A comparative study of different online model parameters identification methods for lithium-ion battery[J]. Science China Technological Sciences, 2021, 64(10): 2312-2327.
- [13] KIM J H, MOON J H, HWANG E J, et al. Recurrent inception convolution neural network for multi short-term load forecasting [J]. Energy and Buildings, 2019, 194: 328-341.
- [14] 李苏阳, 陈富安. 基于注意力机制的双向 LSTM 锂电池 SOH 估算模型[J]. 电源技术, 2022, 46(7): 739-742.
LI S Y, CHEN F AN. Lithium battery SOH prediction based on Bi-LSTM attention mechanism [J]. Chinese Journal of Power Sources, 2022, 46(7): 739-742.
- [15] 刘泽, 张闯, 齐磊, 等. 基于 CNN-BiLSTM 的锂电池剩余使用寿命概率密度评估[J]. 电源技术, 2023, 47(1): 57-61.
LIU Z, ZHANG CH, QI L, et al. Prediction of probability density of remaining useful life of lithium ion battery based on CNN-BiLSTM [J]. Chinese Journal of Power Sources, 2023, 47(1): 57-61.
- [16] ZHAO L P, WU K Y. Mach number prediction for a wind tunnel based on the CNN-LSTM-attention method[J]. Instrumentation, 2023, 10(4): 64-82.
- [17] 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.
- [18] 张梁, 高源, 杨光, 等. BP 神经网络模型的改进及其在海底管道外腐蚀速率预测中的应用[J]. 安全与环境学报, 2023, 23(11): 3882-3888.
ZHANG L, GAO Y, YANG G, et al. Improvement of the BP neural network model and its application in the prediction of the external corrosion rate of submarine pipeline [J]. Journal of Safety and Environment, 2023, 23(11): 3882-3888.

作者简介

陈鑫, 硕士研究生, 主要研究方向为退役电池健康状态评估。

E-mail: 2359326290@qq.com

廖强强(通信作者), 博士, 教授, 硕士研究生导师, 主要研究方向为动力电池回收与梯次利用。

E-mail: 13371895959@163.com