

DOI: 10.19783/j.cnki.pspc.230606

# 计及健康特征信息量的锂离子电池健康状态与 剩余寿命预测研究

岳家辉<sup>1</sup>, 夏向阳<sup>1</sup>, 吕崇耿<sup>1</sup>, 吴小忠<sup>2</sup>, 孔林<sup>3</sup>, 张媛<sup>1</sup>, 陈来恩<sup>1</sup>

(1. 长沙理工大学电气与信息工程学院, 湖南 长沙 410114; 2. 国网湖南省电力有限公司, 湖南 长沙 410004;  
3. 中国能源建设集团湖南省电力设计院有限公司, 湖南 长沙 410004)

**摘要:** 电池状态有效评估过程中数据驱动法的模型输入虽与容量呈现相关性, 但并没有考虑其信息量及信息质量, 低质量的数据输入会造成一定程度的预测偏差。针对上述问题, 提出一种计及健康特征信息量的加权神经网络电池健康状态(state of health, SOH)预测与剩余寿命(remaining useful life, RUL)估计模型。该模型在 GA-BP 神经网络的基础上, 通过确定有效健康特征数据集, 利用数据信息度构建动量因子来保证神经网络迭代收敛速度。并基于熵权思想过滤出低信息量健康特征的预测结果, 将过滤后的预测结果作为电池老化模型的输入, 进一步实现剩余寿命的估计。通过公开电池老化数据集与实验平台进行验证, 得到该模型健康状态预测结果 MAE、RMSE 分别控制在 0.63%、0.81% 之下, 剩余寿命估计结果 MAE、RMSE 分别控制在 0.0031 mA·h、0.0042 mA·h 之下, 具有良好的可行性与有效性。

**关键词:** 锂离子电池; 数据驱动技术; 健康状态; 剩余使用寿命; 神经网络; 熵权法

## Research on the prediction of state of health and remaining useful life of lithium-ion batteries considering the amount of health factors information

YUE Jiahui<sup>1</sup>, XIA Xiangyang<sup>1</sup>, LÜ Chonggeng<sup>1</sup>, WU Xiaozhong<sup>2</sup>, KONG Lin<sup>3</sup>, ZHANG Yuan<sup>1</sup>, CHEN Laien<sup>1</sup>

(1. School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410114, China; 2. State Grid Hunan Electric Power Co., Ltd., Changsha 410004, China; 3. China Energy Construction Group Hunan Electric Power Design Institute Co., Ltd., Changsha 410004, China)

**Abstract:** The model input of the data-driven method in the effective evaluation process of battery state, although related to capacity, does not consider its information content and quality. Low-quality data input can cause a certain degree of prediction bias. To address this issue, this paper proposes a weighted neural network battery SOH prediction and RUL estimation model that takes into account the degree of health factor information. Based on the GA-BP neural network, this model identifies effective health feature data sets and uses data information to generate momentum factors to ensure neural network iteration convergence speed. And this paper filters out low information health feature prediction findings using the entropy weight concept and then uses the filtered prediction results as the input to the battery aging model to further achieve the RUL estimation. It is discovered through the publicly available battery aging datasets and experimental platforms that the model's SOH prediction results have a MAE and RMSE range controlled within 0.63% and 0.81%, and the remaining useful life estimation results have a MAE and RMSE range controlled within 0.0031 mA·h and 0.0042 mA·h, indicating good feasibility and effectiveness.

This work is supported by the National Natural Science Foundation of China (No. 51977014).

**Key words:** lithium-ion battery; data-driven technology; state of health; remaining useful life; neural network; entropy weight method

## 0 引言

2022年, 国家发展改革委和国家能源局印发的

**基金项目:** 国家自然科学基金项目资助(51977014); 湖南省研究生科研创新项目资助(CX20220917)

《“十四五”新型储能发展实施方案》中明确: 在新型电力系统发展过程中, 明细储能电池本质安全控制、电化学储能电站全面安全预警、实现储能电站安全体系跨越式发展, 是储能发展的核心攻关方向; 同年, 《国家自然科学基金“十四五”发展规划》中将“实现可再生能源的规模化安全高效储能”作为工

程与材料学部重点发展目标<sup>[1]</sup>。储能电站的高效安全储能离不开电池管理系统(battery management system, BMS)的有效监测, 其中表征电池老化程度的重要指标为电池健康状态(state of health, SOH)与剩余寿命(remaining useful life, RUL)<sup>[2-5]</sup>。

储能用锂离子电池的劣化程度主要受外部因素与内部因素共同影响<sup>[6]</sup>。外部因素指电池的使用环境及条件, 如环境温度、充放电倍率与放电深度等; 内部因素指电池的活性锂离子、正负极活性材料与电导率的损失等。基于此, 为实现电池健康状态与剩余寿命的有效评估, 从电池的内外特征参数角度分析, 其方法主要分为三大类: 直接实验法、构建模型与数据驱动<sup>[7-9]</sup>。

直接实验法主要通过通过对电池全充全放获取电池的现有可用容量; 通过电化学阻抗法(electrochemical impedance spectroscopy, EIS)获取电池的内特性参数<sup>[10-11]</sup>, 如欧姆内阻、极化电阻等。该方法直观研究电池退化机理本质, 通过大量实验分析电池劣化程度以实现电池 SOH 与 RUL 的估计。但在储能系统中, 直接实验的条件苛刻且十分耗时, 并不适用于电池管理系统中。

构建模型法一般包括: Rint 等效电路模型、Thevenin 等效电路模型、二阶 RC 等效电路模型<sup>[12]</sup>、PNGV 等效电路模型、GNL 等效电路模型等。同时基于多种自适应滤波<sup>[13-15]</sup>, 如扩展卡尔曼滤波、H<sub>∞</sub>观测器和滑动模块观测器, 以实现电池等效电路模型中内特性参数的有效辨识, 但模型的构建难度及相应的矩阵运算压力是不可忽视的<sup>[16]</sup>。

数据驱动法最大的特点在于无需对电池复杂的劣化过程作详细的建模分析, 略去了计算量繁杂的电池内特性参数辨识过程, 并且不受电池种类的影响, 但该方法的关键点在于数据的预处理及健康特征(health factor, HF)的有效提取与估计方法的确<sup>[17-18]</sup>。多数文献将健康特征的提取聚焦于恒流恒压(constant current/constant voltage, CC/CV)充放电过程中的容量变化量、电压变化量、电流变化量与时间变化量及以上数据的二次处理, 如: 文献[19]选取等电压间隔下的容量变化量作为健康特征以构建健康状态评价体系; 文献[20]将 CC 充电过程中不同时间间隔下的电压变化量与 CV 充电过程中不同时间间隔下的电流变化量作为健康特征, 以实现锂电池健康状态与剩余寿命的预测; 文献[21]选择 CV 充电阶段某一电压升高片段所需时间、CC 充电阶段某一电流下降片段所需时间与循环圈数来作为健康特征以实现锂电池剩余寿命的预测; 文献[22]选择 CC/CV 充电时间及其比值、电流与温度曲线的积

分及 CV 曲线与 CC 曲线上的最大斜率等共计 12 个健康特征; 文献[23]选取 CC 充电阶段某一电压片段的速率作为健康特征, 并来对锂离子容量衰退量进行预测; 文献[24]通过任意起始容量以 CC 方式进行全充的充电数据来构建电池的健康状态估算模型; 文献[25]基于电压-容量关系求一阶导数并绘制容量增量曲线  $V-dQ/dV$ , 通过提取曲线的关键特征点作为健康特征, 以实现健康状态的评估。

在筛选出特征数据构建健康特征作为模型算法的输入后, 模型算法的研究同样关键。神经网络具有挖掘健康特征与健康状态及剩余寿命非线性关系的优势, 在电池状态预测领域已然得到广泛应用。文献[26]将电池电化学阻抗谱的实虚部、模值作为输入量, 结合 BP 神经网络构建 SOH 快速评估模型; 文献[27]基于灰色神经网络模型, 通过在线估算与离线训练构建模型框架进而实现电池容量退化量的估算; 文献[28]通过自适应权重将 CNN-LSTM 网络与 GRU 网络组合, 对各网络预测结果进行叠加融合实现 SOH 的在线估计; 文献[29]同样选取 CNN 神经网络对电池 SOH 进行估算; 文献[30]通过 BP 神经网络、RBF 神经网络与 GRNN 神经网络构建加权混合模型, 将各网络电池 SOH 与 RUL 预测结果进行线性叠加。

综上所述, 数据驱动法模型的构建可大致分为: 多健康特征输入与单神经网络相结合、多健康特征输入与多神经网络相结合以及多健康特征输入与改进神经网络相结合。但很多预测模型的使用并没有考虑健康特征的信息质量, 过低的数据质量会造成一定程度的预测偏差。基于此, 本文在 GA-BP 神经网络的基础上, 提出一种计及健康特征信息量的加权神经网络的电池 SOH 与 RUL 联合预测模型, 即在神经网络输出权重增添数据信息度修正参数, 保证迭代收敛速度, 并基于熵权思想来过滤出低信息量的健康特征预测结果, 增强模型的抗干扰能力与鲁棒性。

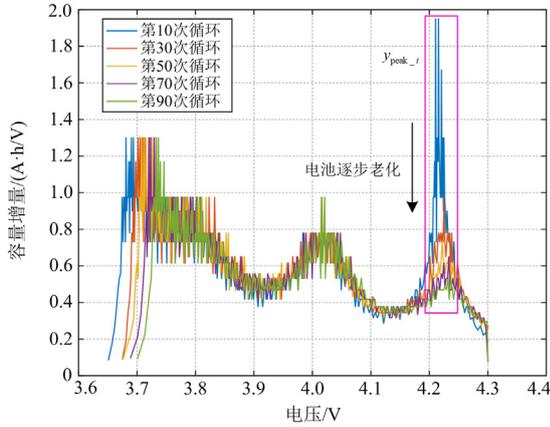
## 1 电池健康特征的讨论

现有研究对于电池健康状态的获取主要从容量、能量与内阻这三个指标出发, 通过对指标的实时直接/间接监测或对指标数据的再处理来实现对当前电池健康状态的有效评估。

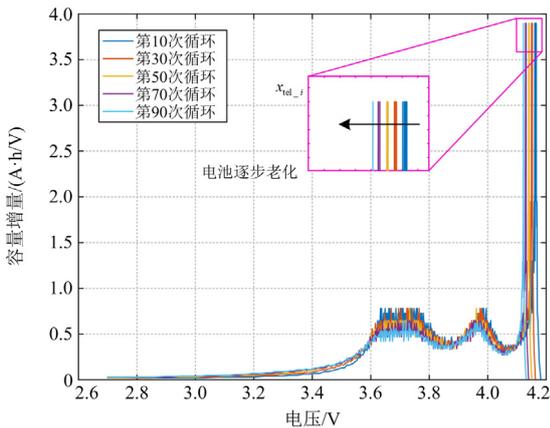
### 1.1 与容量相关

对电池在恒流充电或放电工况下的端电压-容量( $V-Q$ )曲线求一阶导数得到端电压-容量变化率( $V-dQ/dV$ )曲线, 基于该曲线进而发展为容量增量分析(incremental capacity analysis, ICA)法<sup>[31]</sup>。此类方

法以电池充放电电压曲线为基础,从 IC 曲线中提取多个特征参数(包括峰高度、峰位置等)来作为健康特征进行分析,如图 1 所示。上述参数的变化可以有效反映锂离子电池的老化程度,从而实现了对电池健康状态的评估与管理。



(a) 充电过程容量增量曲线的峰高度变化



(b) 放电过程容量增量曲线的峰位置变化

图 1 容量增量曲线变化趋势图

Fig. 1 Change trend of incremental capacity curve

### 1.2 与能量相关

随着电池的逐渐老化,其能够存储的最大能量逐渐下降,因此可以将该健康特征与健康状态建立高保真映射关系。但在电池工作过程中,少有全充全放的运行工况,一般多以某电压片段的最大充电能量作为健康特征。同时,电池充电能量存在突增现象,而这种现象存在污染数据的可能,如图 2 所示,因此当建立大数据模型的同时,同样需要考虑数据质量。

### 1.3 与电压相关

以恒流放电过程为例,整个放电过程可以分为放电初始片段、放电稳定片段、放电结束片段与放电恢复片段,每个电压片段都存在一定的健康特征<sup>[32]</sup>。

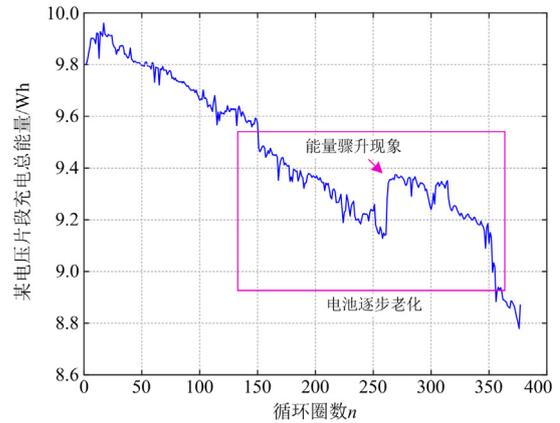


图 2 电池充电能量变化趋势图

Fig. 2 Change trend of battery charging energy

聚焦于放电过程中的瞬时压降幅值,该压降主要由欧姆内阻  $r_{ohm}$  造成,由于电池的逐渐老化,欧姆内阻逐渐增加,该瞬时压降逐渐增大,基于 NASA 公开的 18650 型锂电池老化数据中 B0005 电池绘制相关电压曲线,如图 3 所示。

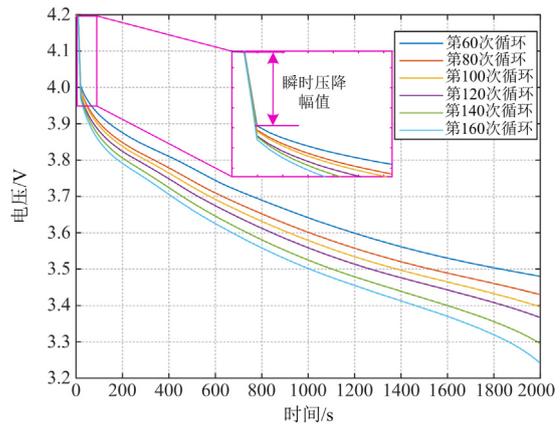


图 3 恒流放电过程瞬时压降幅值变化趋势图

Fig. 3 Change trend of sharp voltage drop during constant current discharge process

聚焦于放电过程中的平稳压降幅值,该压降主要由极化电阻  $r_p$  造成,随着电池的逐渐老化,该平稳压降幅值逐渐增大,基于 NASA 公开的 18650 型锂电池老化数据中 B0005 电池绘制相关电压曲线,如图 4 所示。

### 1.4 与时间相关

根据安时积分法,电池容量的大小是对电流的积分,因此部分学者聚焦于恒流充电时间(constant current charge time, CCCT)与恒流放电时间(constant current discharge time, CCDT)。

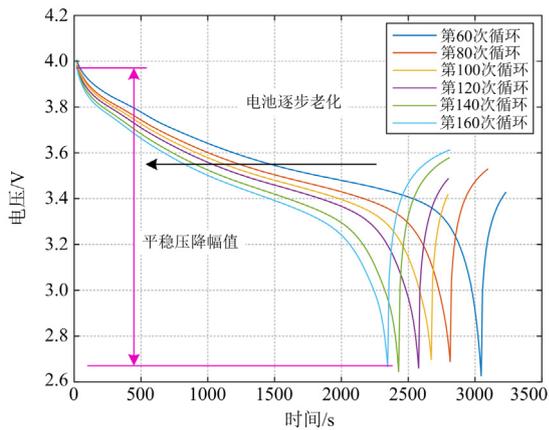


图 4 恒流放电过程平穩压降幅值变化趋势图

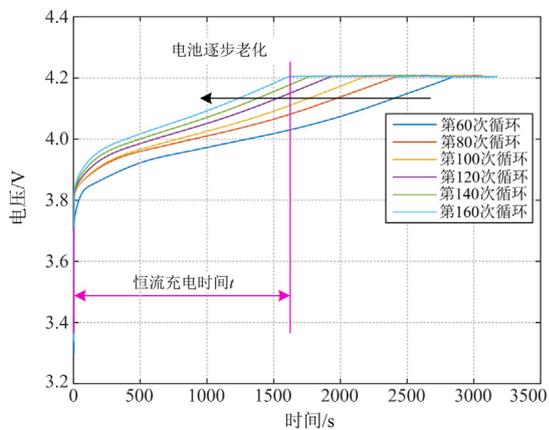
Fig. 4 Change trend of slow voltage drop during constant current discharge process

随着电池的逐渐老化, 电化学性能降低, 若电流保持不变, 恒流过程持续时间会逐渐减少, 基于 NASA 公开的 18650 型锂电池老化数据绘制相关电压曲线, 如图 5 所示。

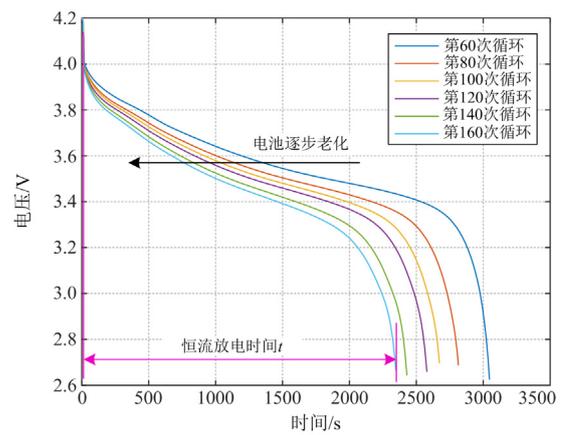
### 1.5 与温度相关

随着电池的逐渐老化, 欧姆内阻与极化内阻显著增大, 在恒流充电过程中电池最高温度逐渐增大。同时, 由于电池温度的升高, 部分学者采用某一温度片段变化率作为健康特征。同样基于 NASA 公开的 18650 型锂电池老化数据绘制单体温度曲线, 如图 6 所示。

综上所述, 电池的历史运行数据存在大量反应电池健康状态的健康特征 HF, 但显而易见的是数据驱动法可实施的关键点在于收集大量电池循环老化数据, 须花费几个月甚至更长的时间; 同时, 需要对大量老化数据进行准确过滤, 构建健康因子数据集以保证模型的稳定性及其预测结果的准确性<sup>[33]</sup>。



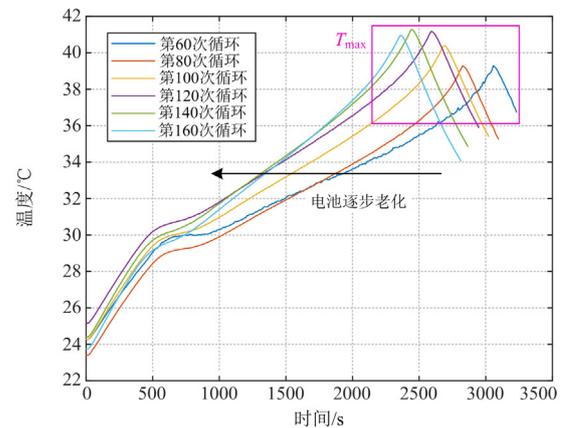
(a) 恒流充电时间变化情况



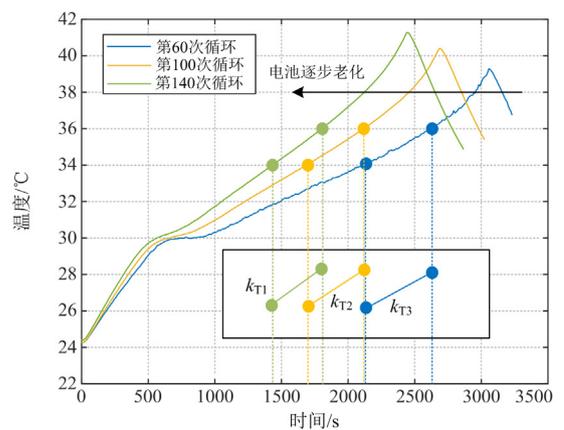
(b) 恒流放电时间变化情况

图 5 恒流充放电时间变化趋势图

Fig. 5 Change trend of constant current charging and discharging time



(a) 放电过程电池最高温度变化趋势



(b) 放电过程电池温度变化速率变化趋势

图 6 恒流放电过程中电池温度变化趋势图

Fig. 6 Change trend of temperature during constant current discharge process

## 1.6 健康特征的因果关系分析

由于选择特征数据的不同, 电池老化过程中数据的波动幅值不同, 所包含的信息量也不尽相同, 其与容量之间所传递的信息量, 即两者因果关系存在差别。本节基于公开 18650 电池老化数据, 通过传递熵(transfer entropy)对放电能量  $Q$ 、恒流充电时间与与放电容量的因果关系进行计算, 计算公式为

$$T_{j \rightarrow i} = \sum_{i_{n+1}, i_n, j_m} p(i_{n+1}, i_n^{(k)}, j_m^{(l)}) \log \frac{p(i_{n+1} | i_n^{(k)}, j_m^{(l)})}{p(i_{n+1} | i_n^{(k)})} \quad (1)$$

式中:  $i_n$  为  $i$  在  $n$  时刻的测量值;  $j_m$  为  $j$  在  $m$  时刻的测量值;  $i_{n+1}$  在  $n+1$  时刻的测量值;  $k$  为变量  $i$  的维度,  $l$  为变量  $j$  的维度;  $p(i_{n+1}, i_n^{(k)}, j_m^{(l)})$  为  $i_{n+1}$ 、 $i_n^{(k)}$  与  $j_m^{(l)}$  的联合概率密度函数;  $p(i_{n+1} | i_n^{(k)})$  表示  $i_n^{(k)}$  向  $n+1$  时刻状态  $i_{n+1}$  传递的信息量;  $p(i_{n+1} | i_n^{(k)}, j_m^{(l)})$  表示  $i_n^{(k)}$  和  $j_m^{(l)}$  向  $n+1$  时刻状态  $i_{n+1}$  传递的信息量, 即表现出测量值  $j$  对测量值  $i$  未来状态的参与影响程度。

将健康因子视为“因”, 放电容量视为“果”, 计算各健康因子对于放电容量的传递熵。

由表 1 可以看出, 不同的健康因子对于电池老化的因果性是不一致的, 所传递的信息量并不相同, 因此本文通过 GA-IBP 神经网络构建计及健康特征信息量的加权神经网络预测模型, 实现对电池健康状态 SOH 的表征与预测, 进而实现 RUL 的准确估计。

表 1 传递熵计算结果

Table 1 Calculation results of transfer entropy

健康特征	传递熵/bit
放电能量	2.3007
恒流充电时间	2.1852
恒流放电时间	0.8300

## 2 GA-IBP+EWM 实现方法

### 2.1 引入动量项的 BP 神经网络反向传播

神经网络的输入为  $\mathbf{X} = [x_1, x_2, \dots, x_t]$ , 连接权重为  $\mathbf{A} = [\omega_1, \omega_2, \dots, \omega_t]$ , 其中  $t$  为模型输入个数, 则神经网络的输出为

$$\begin{cases} \mathbf{Z} = \mathbf{A}^T \cdot \mathbf{X} + \mathbf{b} \\ \mathbf{a} = \sigma(\mathbf{Z}) \end{cases} \quad (2)$$

令  $\mathbf{a}$  为预测值,  $\mathbf{y}$  为实际值, 损失函数为  $L(\mathbf{a}, \mathbf{y})$ , 对损失函数求偏导数<sup>[34]</sup>得

$$\begin{cases} \frac{\partial L(\mathbf{a}, \mathbf{y})}{\partial \mathbf{A}} = \frac{\partial L(\mathbf{a}, \mathbf{y})}{\partial \mathbf{a}} \cdot \frac{\partial \mathbf{a}}{\partial \mathbf{Z}} \cdot \frac{\partial \mathbf{Z}}{\partial \mathbf{A}} \\ \frac{\partial L(\mathbf{a}, \mathbf{y})}{\partial \mathbf{b}} = \frac{\partial L(\mathbf{a}, \mathbf{y})}{\partial \mathbf{a}} \cdot \frac{\partial \mathbf{a}}{\partial \mathbf{Z}} \cdot \frac{\partial \mathbf{Z}}{\partial \mathbf{b}} \end{cases} \quad (3)$$

根据式(3), 基于梯度下降法通过误差的反向传播实现对每层权重和阈值的更新, 其目的在于经过不断的迭代和更新, 使得损失函数  $L(\mathbf{a}, \mathbf{y})$  最小化, 则 BP 神经网络的输出层权重梯度可写为

$$\frac{\partial L}{\partial \omega_{m_1 n_1}^2} = \frac{\partial L}{\partial s_{k_1}^2} \cdot \frac{\partial s_{k_1}^2}{\partial \omega_{m_1 n_1}^2} \quad (4)$$

式中:  $\partial \omega_{m_1 n_1}^2$  为隐含层第  $m_1$  个节点至输出层第  $n_1$  个节点的权重;  $\partial s_{k_1}^2$  为输出层第  $k_1$  个节点输入。权重大小沿负方向移动, 记为

$$\nabla \omega = -\frac{\partial L}{\partial \omega_j} \quad (5)$$

则连接权重更新为

$$\omega_{q+1} = \omega_q + \eta \cdot \nabla \omega_q \quad (6)$$

式中:  $\omega_{q+1}$  为更新权重;  $\omega_q$  为更新前权重;  $\eta$  为学习效率, 取值在 0~1 之间。

由于神经网络输入数据的信息有效值不同, 为保证低信息量数据的迭代收敛速度, 本文提出一个计及数据信息有效性的动量因子, 如式(7)所示。

$$\begin{cases} e(n_2) = \frac{1}{n_2 + 1} \left[ \sum_{i=1}^{n_2} (\hat{y} - y)^2 + (\hat{d} - d) \right] \\ \omega_{q+1} = \omega_q + \eta \cdot \nabla \omega_q + \theta [1 - e^{-e(n_2)}] \cdot \nabla \omega_{q-1} \end{cases} \quad (7)$$

式中:  $\hat{y}$  为模型预测结果;  $d$  为整体数据集期望有效值;  $\hat{d}$  为整体数据集预测后的数据有效值;  $n_2$  为预测结果个数;  $\rho$  为控制动量因子变化幅值, 是一常数;  $\theta$  为常数, 控制动量因子上升速率。

### 2.2 遗传算法

将预测值与实际值的误差之和视为个体适应度值的计算函数, 计算式为

$$F = k_2 \left( \sum_{\delta=1}^n |a_\delta - y_\delta| \right) \quad (8)$$

在遗传算法中, 采用轮盘赌法完成遗传算法的选择操作, 设个体  $\delta$  的选择概率  $P_\delta$  为

$$\begin{cases} P_\delta = \frac{f_\delta}{\sum_{j=1}^{N_1} f_j} \\ f_\delta = \frac{k_2}{F_\delta} \end{cases} \quad (9)$$

式中:  $k_2$  为系数;  $N_1$  为种群个体总数;  $F_\delta$  表示个体  $\delta$  的误差之和, 其值越小说明精度越佳;  $f_\delta$  表示个体  $\delta$  对应的适应度值。

采用交叉操作, 将第  $k_3$  个染色体和第  $l_1$  个染色

体在  $h$  位进行交叉操作, 其方法为

$$\begin{cases} \delta_{k_3h} = \delta_{k_3h} \cdot (1 - \gamma) + \delta_{l_1h} \cdot \gamma \\ \delta_{l_1h} = \delta_{l_1h} \cdot (1 - \gamma) + \delta_{k_3h} \cdot \gamma \end{cases} \quad (10)$$

式中:  $\delta_{k_3h}$  为第  $k_3$  个染色体点在  $h$  位的值;  $\delta_{l_1h}$  为第  $l_1$  个染色体在  $h$  位的值;  $\gamma$  为  $[0,1]$  区间的随机数。

采用变异操作, 即选择个体  $\delta$  的第  $n_3$  个基因进行变异操作, 如式(11)所示。

$$\phi_{n_3} = \begin{cases} \phi_{n_3} + (\phi_{\max} - \phi_{n_3}) \cdot [\tau(1 - \kappa/G_{\max})^2] & \tau > 0.5 \\ \phi_{n_3} + (\phi_{n_3} - \phi_{\min}) \cdot [\tau(1 - \kappa/G_{\max})^2] & \tau \leq 0.5 \end{cases} \quad (11)$$

式中:  $\phi_{\max}$ 、 $\phi_{\min}$  分别为基因取值的上下限;  $\kappa$  为现在的迭代次数;  $G_{\max}$  为迭代次数最大值;  $\tau$  为  $[0,1]$  区间的随机数。

通过选择操作、交叉操作、变异操作, 实现 BP 神经网络初始权重阈值的寻优。

### 2.3 计及数据信息量的综合赋权

从热力学角度出发, 熵用于描述物质运动随机程度, 熵值的大小仅与观测对象的起止状态有关, 因此系统无序性与脆弱性的演化程度可以通过熵值大小进行判断, 其中信息熵值定义为

$$H = -c \sum_{i=1}^{N_2} P(x_i) \log_{\varepsilon} P(x_i) \quad (12)$$

式中:  $P(x_i)$  为事件  $x_i$  发生概率;  $N_2$  为系统状态可能出现的总数;  $c$  是任意常数, 若无特殊说明, 取 1; 底数  $\varepsilon$  决定熵值单位。当底数  $\varepsilon$  取 2 时, 则信息熵的单位为“Bit”; 当  $\varepsilon$  取  $e$  时, 则信息熵的单位为“Nat”; 当  $\varepsilon$  取 10 时, 则信息熵的单位为“Hart”。不同于统计学领域对熵值的解释, 在信息学领域中, 数据熵值越小, 表示该数据包含的信息越多, 数据熵值越大, 表示该数据包含的信息越少。

假设存在一个理想的单原子气体, 在稳态条件下, 其熵方程为

$$s = \frac{5N_3k_b}{2} + N_3k_b \ln \left[ \frac{Vg^*}{N_3} \left( \frac{4\pi m_2 E}{3N_3 h_p^2} \right)^{3/2} \right] \quad (13)$$

式中:  $N_3$  为气体分子数;  $k_b$  为玻尔兹曼常数;  $V$  为容器的体积;  $m_2$  为原子的质量;  $g^*$  为原子中不可识别的基态数;  $E$  为总能量;  $h_p$  为普朗克常数。

当容量体积由  $V_0$  增大至  $V_1$  时, 熵增量为

$$\Delta S = N_3k_b (\ln V_1 - \ln V_0) > 0 \quad (14)$$

则该过程的数据丢失为

$$e = \frac{\Delta H}{k_b \ln 2} \quad (15)$$

式中,  $\Delta H$  为气体体积增加后熵的变化幅值。

在信息论中, 熵的增大意味着数据的不断破坏或者丢失, 其为一种衡量数据缺乏程度的物理量。基于上述熵-信息量的关系, 本文提出一种计及数据特征数据信息量的电池健康状态与剩余寿命的预测方法。

首先对健康特征进行归一化, 当该数据为正向指标时, 归一化计算式如式(16)所示。

$$Y = \frac{y_i - \min\{y_1, \dots, y_{n_4}\}}{\max\{y_1, \dots, y_{n_4}\} - \min\{y_1, \dots, y_{n_4}\}} \quad (16)$$

式中:  $n_4$  为健康特征数量;  $y_i$  为特征数据数值。

当该数据为负向指标时, 归一化计算式如式(17)所示。

$$Y = \frac{\max\{y_1, \dots, y_{n_4}\} - y_i}{\max\{y_1, \dots, y_{n_4}\} - \min\{y_1, \dots, y_{n_4}\}} \quad (17)$$

以选取 3 种健康特征为例, 则健康特征数据的信息熵为

$$\begin{cases} H_1 = -\sum_{K=1}^{n_4} p_{1_K}(Y_{1_i}) \ln p_{1_K}(Y_{1_i}) \\ H_2 = -\sum_{K=1}^{n_4} p_{2_K}(Y_{2_i}) \ln p_{2_K}(Y_{2_i}) \\ H_3 = -\sum_{K=1}^{n_4} p_{3_K}(Y_{3_i}) \ln p_{3_K}(Y_{3_i}) \end{cases} \quad (18)$$

式中:  $Y_{1_i}$ 、 $Y_{2_i}$ 、 $Y_{3_i}$  为健康特征归一化后的数值;  $p_{1_K}(Y_{1_i})$ 、 $p_{2_K}(Y_{2_i})$ 、 $p_{3_K}(Y_{3_i})$  分别为健康特征归一化后在第  $K$  个数值区间的发生概率。

各特征参数信息有效值为

$$\begin{cases} d_1 = 1 - H_1 \\ d_2 = 1 - H_2 \\ d_3 = 1 - H_3 \end{cases} \quad (19)$$

权重为

$$\begin{cases} \omega_{H_1} = \frac{d_1}{3 - \sum_{r=1}^3 H_r} \\ \omega_{H_2} = \frac{d_2}{3 - \sum_{r=1}^3 H_r} \\ \omega_{H_3} = \frac{d_3}{3 - \sum_{r=1}^3 H_r} \end{cases} \quad (20)$$

基于信息学思想, 当特征数据熵值越小时, 可认为该数据包含信息越多, 该特征数据对综合判断结果的影响(即权重)就越大; 当特征数据熵值越大时, 可认为该数据包含信息越少, 该特征数据对综合判断结果的影响(即权重)就越小。

一般情况下,多数文献通过数次连续性实验,依据平均绝对误差 MAE 来确定权重,其计算式如式(21)所示。

$$\left\{ \begin{array}{l} M_{AE} = \frac{1}{n_4} \sum_{k=1}^{n_4} |\text{真实值} - \text{预测值}| \\ \omega_{H_1} = \frac{1/M_{AE}(Y_1)}{\sum_{r=1}^3 (1/M_{AE}(Y_r))} \\ \omega_{H_2} = \frac{1/M_{AE}(Y_2)}{\sum_{r=1}^3 (1/M_{AE}(Y_r))} \\ \omega_{H_3} = \frac{1/M_{AE}(Y_3)}{\sum_{r=1}^3 (1/M_{AE}(Y_r))} \end{array} \right. \quad (21)$$

式中:  $r$  为特征数据的选取个数;  $M_{AE}(Y_r)$  为健康特征  $HF_r$  对于电池健康状态预测结果的平均绝对误差。

本文从数据质量出发,通过 GA-IBP 神经网络,计及数据信息量,根据熵权重进行再次预测,预测函数为

$$S_{OH\ pre} = \omega_{H_1} \cdot s_{oh\_predict}(Y_1) + \omega_{H_2} \cdot s_{oh\_predict}(Y_2) + \omega_{H_3} \cdot s_{oh\_predict}(Y_3) \quad (22)$$

式中,  $s_{oh\_predict}(Y_1)$ 、 $s_{oh\_predict}(Y_2)$ 、 $s_{oh\_predict}(Y_3)$  分别为健康特征  $HF_1$ 、 $HF_2$ 、 $HF_3$  对于电池健康状态的预测结果。

$$\left\{ \begin{array}{l} M_{AE} = \frac{1}{n_4} \sum_{k=1}^{n_4} |\text{真实值} - \text{预测值}| \\ \omega_1^* = \frac{1/M_{AE}(Y_1)}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (M_{AE}(S_{EWM}))} \\ \omega_2^* = \frac{1/M_{AE}(Y_2)}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (M_{AE}(S_{EWM}))} \\ \omega_3^* = \frac{1/M_{AE}(Y_3)}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (M_{AE}(S_{EWM}))} \\ \omega_4^* = \frac{1/M_{AE}(S_{EWM})}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (M_{AE}(S_{EWM}))} \end{array} \right. \quad (23)$$

在 MAE 赋权的基础上,通过数次连续性实验确定权重结果来对电池健康状态进行重新预测,预测函数为

$$S_{OH\ pre} = \omega_1^* \cdot s_{oh\_predict}(Y_1) + \omega_2^* \cdot s_{oh\_predict}(Y_2) + \omega_3^* \cdot s_{oh\_predict}(Y_3) + \omega_4^* \cdot s_{oh\_predict}(S_{EWM}) \quad (24)$$

式中:  $s_{oh\_predict}(Y_1)$ 、 $s_{oh\_predict}(Y_2)$ 、 $s_{oh\_predict}(Y_3)$  分别为健康特征  $HF_1$ 、 $HF_2$ 、 $HF_3$  对于电池健康状态的预测结果;  $s_{oh\_predict}(S_{EWM})$  为基于特征数据信息量的电池健康状态预测结果;  $\omega_1^*$ 、 $\omega_2^*$ 、 $\omega_3^*$ 、 $\omega_4^*$  为计及数据质量的权重,  $\omega_1^* + \omega_2^* + \omega_3^* + \omega_4^* = 1$ 。预测流程如图 7 所示。

同时,本文通过 GA-IBP 神经网络,在绝对误差 MAE 赋权的基础上,计及数据信息量与 SOH 预测结果,实现对电池剩余寿命的预测。

首先通过 GA-IBP 神经网络,并计及数据质量,根据熵权重进行再次预测,预测函数为

$$R_{EWM} = \omega_{H_1} \cdot r_{ul\_predict}(Y_1) + \omega_{H_2} \cdot r_{ul\_predict}(Y_2) + \omega_{H_3} \cdot r_{ul\_predict}(Y_3) \quad (25)$$

式中,  $r_{ul\_predict}(Y_1)$ 、 $r_{ul\_predict}(Y_2)$ 、 $r_{ul\_predict}(Y_3)$  分别为健康特征  $HF_1$ 、 $HF_2$ 、 $HF_3$  对于电池剩余寿命的预测结果。

依据 SOH 预测结果,进而得到剩余寿命预测结果,其函数为

$$R_{SOH} = r_{ul\_predict}(S_{OH\ pre}) \quad (26)$$

基于上述预测结果,并代入式(21)重新进行综合赋权,如式(27)所示。

$$\left\{ \begin{array}{l} M_{AE} = \frac{1}{n_4} \sum_{k=1}^{n_4} |\text{真实值} - \text{预测值}| \\ \omega'_1 = \frac{1/M_{AE}(Y_1)}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (1/M_{AE}(R_{EWM})) + (1/M_{AE}(R_{SOH}))} \\ \omega'_2 = \frac{1/M_{AE}(Y_2)}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (1/M_{AE}(R_{EWM})) + (1/M_{AE}(R_{SOH}))} \\ \omega'_3 = \frac{1/M_{AE}(Y_3)}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (1/M_{AE}(R_{EWM})) + (1/M_{AE}(R_{SOH}))} \\ \omega'_4 = \frac{1/M_{AE}(R_{EWM})}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (1/M_{AE}(R_{EWM})) + (1/M_{AE}(R_{SOH}))} \\ \omega'_5 = \frac{1/M_{AE}(R_{SOH})}{\sum_{r=1}^3 (1/M_{AE}(Y_r)) + (1/M_{AE}(R_{EWM})) + (1/M_{AE}(R_{SOH}))} \end{array} \right. \quad (27)$$

在 MAE 赋权的基础上,通过数次连续性实验确定权重结果来对电池剩余寿命进行重新预测,预测函数为

$$R_{UL\_pre} = \omega'_1 \cdot r_{ul\_predict}(Y_1) + \omega'_2 \cdot r_{ul\_predict}(Y_2) + \omega'_3 \cdot r_{ul\_predict}(Y_3) + \omega'_4 \cdot r_{ul\_predict}(R_{EWM}) + \omega'_5 \cdot r_{ul\_predict}(R_{SOH}) \quad (28)$$

式中:  $r_{ul\_predict}(Y_1)$ 、 $r_{ul\_predict}(Y_2)$ 、 $r_{ul\_predict}(Y_3)$  分别为健康特征  $HF_1$ 、 $HF_2$ 、 $HF_3$  对于电池剩余寿命的预

测结果;  $r_{ul\_predict}(R_{EWM})$  为基于特征数据信息量的剩余寿命预测结果;  $r_{ul\_predict}(R_{SOH})$  为基于电池健康状态的剩余寿命预测结果;  $\omega'_1$ 、 $\omega'_2$ 、 $\omega'_3$ 、 $\omega'_4$ 、 $\omega'_5$  为计及数据信息量和健康状态的预测结果权重,  $\omega'_1 + \omega'_2 + \omega'_3 + \omega'_4 + \omega'_5 = 1$ 。预测流程如图 7 所示。

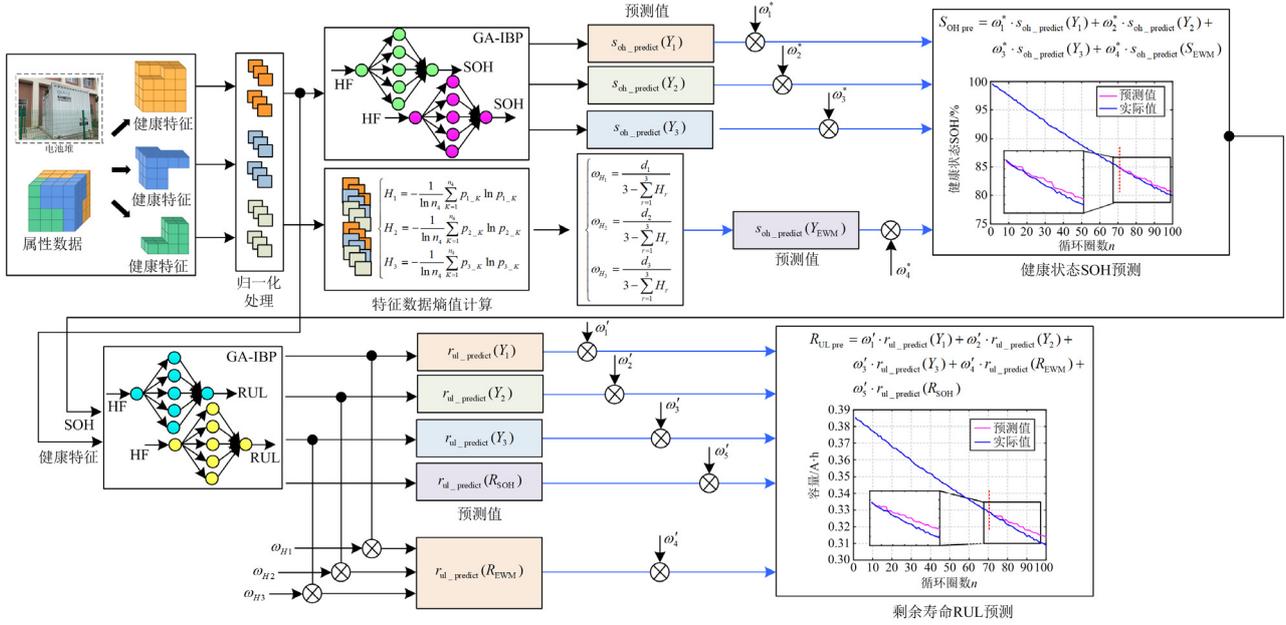


图 7 计及特征数据信息量的锂离子电池健康状态 SOH 与剩余寿命 RUL 联合预测流程

Fig. 7 Prediction process of lithium ion battery SOH and RUL considering characteristic data information

### 3 数据验证

为验证权重确定的有效性, 本节基于公开的 18650 电池老化数据, 选择 2.7 A·h 电池以 2.7 A 电流充电至 4.35 V 后以 27 mA 电流进行恒流充电; 放电阶段以 1.89 A 电流放电至 2 V; 充放电阶段之间静止 10 min; 循环充放电 378 圈, 从第 20 次循环开始, 每循环 5 次采集一次健康特征数据来构建数据集。本文采用安时积分法通过 4.35 V 至 2 V 电压区间的可放电容量来定义当前电池健康状态与剩余寿命。以循环老化数据前 85% 的健康特征数据作为训练样本, 后 15% 的健康特征数据作为测试样本; 神经网络为单健康特征输入, 隐藏层节点为 5; 遗传代数数为 50, 种群规模为 5。

#### 3.1 健康状态预测

本节选择特征数据放电能量  $Q$  与恒流充电时间  $t_c$ 、 $t_d$  作为健康特征, 为确定本文选择健康特征的可行性, 通过 Pearson 及 Spearman 相关性分析法来验证上述健康特征与放电容量  $C$  的相关性, 计算式为

$$P_{\text{pearson}} = \frac{\sum_{I=1}^M (\beta_I - \bar{\beta})(C_I - \bar{C})}{\sqrt{\sum_{I=1}^M (\beta_I - \bar{\beta})^2} \cdot \sqrt{\sum_{I=1}^M (C_I - \bar{C})^2}} \quad (29)$$

$$S_{\text{pearman}} = 1 - \frac{6 \sum_{I=1}^M d_{\lambda}^2}{M(M^2 - 1)} \quad (30)$$

式中:  $M$  为循环周期总数;  $\beta_I$  表示第  $I$  个循环周期的特征数据值;  $C_I$  表示在第  $I$  个循环周期放电容量值;  $\bar{\beta}$  为特征数据平均值;  $\bar{C}$  为放电容量平均值;  $d_{\lambda}$  为特征数据  $\beta$  与电池放电容量  $C$  按照降序排列后所得的位置差。相关性系数计算结果如表 2 所示。

表 2 相关性系数计算结果

Table 2 Calculation result of relevance coefficient

健康特征	Pearson 相关性系数	Spearman 相关性系数
放电能量 $Q$	0.997	0.992
恒流充电时间 $t_c$	0.943	0.917
恒流放电时间 $t_d$	0.993	0.996

由表2可以看出,放电能量 $Q$ 、恒流充电时间 $t_c$ 、恒流放电时间 $t_d$ 与放电容量 $C$ 相关性系数接近于1,呈现高正相关性,因此,将放电能量 $Q$ 与恒流充放电时间 $t_c$ 、 $t_d$ 作为正向指标,则各健康特征熵权重如表3所示。

表3 健康特征熵权重结果

Table 3 Entropy weight result of health feature

健康特征	信息熵值/Nat	熵权重/%
放电能量 $Q$	0.939	40.376
恒流充电时间 $t_c$	0.969	20.279
恒流放电时间 $t_d$	0.94	39.345

通过 GA-IBP 神经网络连续进行 5 次实验,计及数据信息量的混合权重如图8所示。

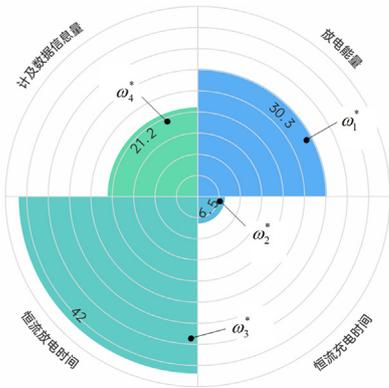


图8 赋权结果

Fig. 8 Result of weighted value

基于所给权重对电池健康状态重新预测,同时给出 MAE 赋权、等值赋权的预测结果,如图9所示。预测结果与实际值的误差情况如表4所示。

由表4可以看出,对于计及数据信息量的电池健康状态预测模型预测结果平均绝对误差和均方根

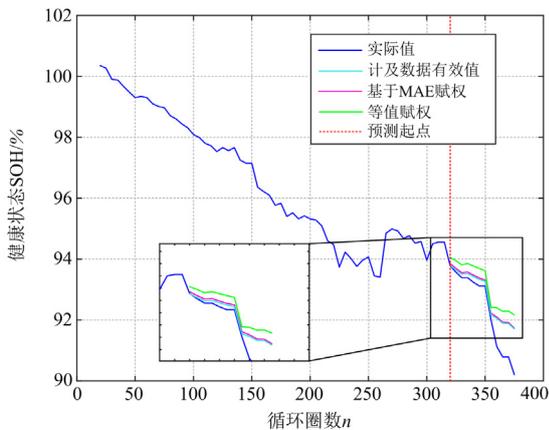


图9 不同赋权下的电池健康状态预测结果

Fig. 9 Prediction results of SOH under different weights

表4 健康状态预测误差统计

Table 4 Prediction error statistics of SOH

预测模型	MAE/%	RMSE/%
计及数据信息量	0.47	0.69
基于 MAE 赋权	0.52	0.71
等值赋权	0.82	0.98

误差的实际值与预测值相近;基于 MAE 赋权与等值赋权预测模型预测结果平均绝对误差与均方根误差均逊于计及数据信息量的预测模型,表明本文所提预测模型具有更好的预测精度与鲁棒性。

### 3.2 剩余寿命预测

测试样本数量与验证样本数量保持不变,通过 GA-IBP 神经网络连续进行 5 次实验,基于计及健康特征信息量与健康状态预测结果进行综合赋权,赋权结果如图10所示。

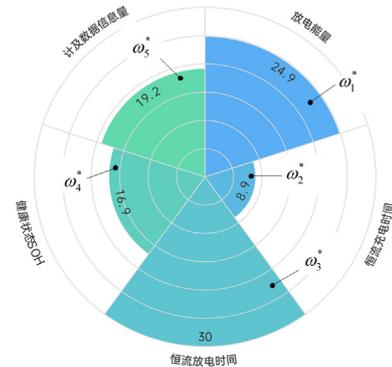


图10 赋权结果

Fig. 10 Result of weighted value

基于所给权重对电池剩余寿命状态重新预测,同时给出 MAE 赋权、等值赋权的预测结果,如图11所示。各预测结果与实际值的误差情况如表5所示。

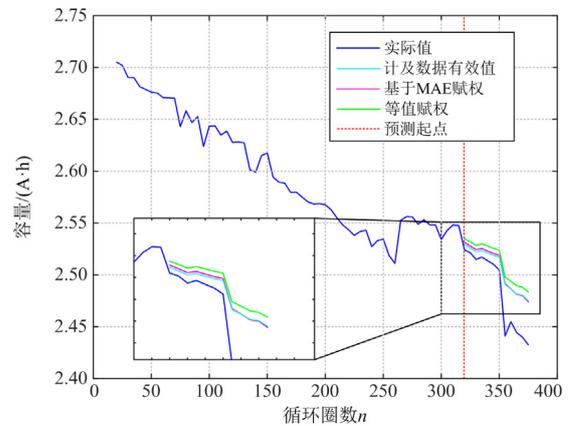


图11 不同赋权下的电池剩余寿命预测结果

Fig. 11 Prediction results of RUL under different weights

表 5 剩余寿命预测误差统计

Table 5 Prediction error statistics of RUL

预测模型	MAE/(A·h)	RMSE/(A·h)
计及数据有效值	0.0211	0.0269
基于 MAE 赋权	0.0222	0.0272
等值赋权	0.028	0.0330

由表 5 可以看出, 对于计及特征数据信息量与健康状态预测结果的电池剩余寿命预测模型平均绝对误差和均方根误差的预测结果同样优于基于 MAE 赋权与等值赋权的剩余寿命预测模型的预测结果。

#### 4 实验验证

为进一步验证所提预测方法的有效性, 基于新威小电流电芯测试平台, 对锂离子扣式电池进行恒流充放电老化实验, 即电池以 0.4 mA 的恒定电流进行充电, 若电池电压达到 4.3 V 则停止充电; 然后以 0.4 mA 的恒定电流进行放电, 若电池电压降至 2.7 V 则停止放电; 每次放电结束后静置 10 s; 时间分辨率为 10 s, 即每 10 s 对电池放电容量及电压进行一次采样; 神经网络参数保持不变。实验平台如图 12 所示。

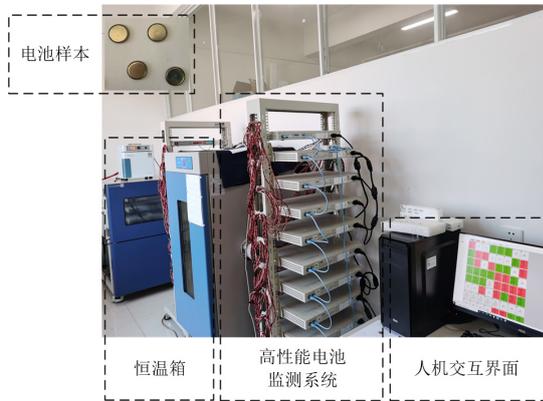


图 12 实验平台与电池样本

Fig. 12 Experiment platform and battery sample

##### 4.1 健康状态预测

选取单体电池  $B_1$  进行恒流充放电老化实验, 由于充放电初始阶段存在电池激活现象, 因此以第 10 圈循环作为起始, 基于安时积分法通过 4.3 V 至 2.7 V 电压变化区间的放电容量来定义电池的 SOH 与 RUL, 本节对充电过程容量增量曲线的峰高度  $y_{peak}$ 、放电过程容量增量曲线的峰位置  $x_{tel}$  及瞬时压降幅值  $\Delta u_{ohm}$  进行采样; 当放电容量衰减为初始的 80% 时, 该电池达到退役标准, 并停止采样; 以循环老化数据的前 70% 特征数据作为训练样本, 后

30% 特征数据作为测试样本。

同样利用 Pearson 及 Spearman 相关性分析法来验证充电过程容量增量曲线的峰高度、放电过程容量增量曲线的峰位置及瞬时压降幅值与放电容量  $C$  的相关性。相关性系数计算结果如表 6 所示。

由表 6 可以看出, 充放电过程容量增量曲线的峰位置  $x_{tel}$  与放电容量  $C$  的相关性系数接近于 1, 呈现高正相关性; 瞬时压降幅值  $\Delta u_{ohm}$  相关性系数接近于 -1, 呈现高负相关性。因此, 基于相关性分析结果, 将放电过程容量增量曲线的峰位置及充电过程容量增量曲线的峰高度作为正向指标, 放电过程瞬时压降幅值作为负向指标, 则各特征数据熵权重如表 7 所示。

表 6 相关性系数计算结果

Table 6 Calculation result of relevance coefficient

电池序号	健康特征	Pearson 相关性系数	Spearman 相关性系数
$B_1$	峰高度 $y_{peak}$	0.898	0.995
	峰位置 $x_{tel}$	0.999	0.999
	瞬时压降幅值 $\Delta u_{ohm}$	-0.998	-1
$B_2$	峰高度 $y_{peak}$	0.875	0.993
	峰位置 $x_{tel}$	0.999	0.999
	瞬时压降幅值 $\Delta u_{ohm}$	-0.997	-1

表 7 电池  $B_1$  健康特征熵权重结果Table 7 Entropy weight result of health feature of battery  $B_1$ 

健康特征	信息熵值/Nat	熵权重/%
峰高度 $y_{peak}$	0.91	48.585
峰位置 $x_{tel}$	0.956	23.849
瞬时压降幅值 $\Delta u_{ohm}$	0.949	27.566

将数据通过 GA-IBP 神经网络连续进行 5 次实验, 计及数据信息量的预测函数为

$$S_{OH_{pre-B1}} = 0.2429 \cdot S_{oh\_predict}(Y_1) + 0.2081 \cdot$$

$$S_{oh\_predict}(Y_2) + 0.2338 \cdot S_{oh\_predict}(Y_3) + (31)$$

$$0.3152 \cdot S_{oh\_predict}(S_{EWM})$$

基于式(31)对电池健康状态重新预测, 同时给出不同神经网络的预测结果, 如图 13 所示。

各模型预测结果与实际值的误差情况如表 8 所示。由表 8 可以看出: 对于电池  $B_1$ , BP、LSTM 与 GA-BP 神经网络预测模型的预测结果平均绝对误差与均方根误差分别为 1.78%、2.09%, 1.71%、1.86% 和 0.99%、1.1%; 计及数据信息量的电池健康状态预测模型的平均绝对误差与均方根误差分别为 0.37%、0.42%, 该预测结果均优于 BP、LSTM 与 GA-BP 神经网络模型。

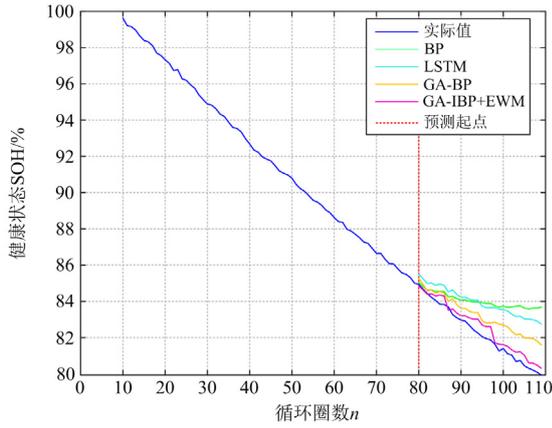


图 13 电池 B<sub>1</sub> 健康状态预测结果

Fig. 13 Prediction results of SOH of battery B<sub>1</sub>

表 8 电池 B<sub>1</sub> 健康状态预测误差统计

Table 8 Prediction error statistics of SOH of battery B<sub>1</sub>

预测模型	MAE/%	RMSE/%
BP	1.78	2.09
LSTM	1.71	1.86
GA-BP	0.99	1.1
GA-IBP+EWM	0.37	0.42

同时选取另枚单体电池 B<sub>2</sub> 进行恒流充放电老化实验, 以第 10 圈循环采样数据作为老化数据起始, 基于安时积分法通过 4.3 V 至 2.7 V 电压变化区间的放电容量来计算电池 B<sub>2</sub> 的 SOH 与 RUL, 同样对峰高度  $y_{peak}$ 、峰位置  $x_{tel}$  及瞬时压降幅值  $\Delta u_{ohm}$  进行采样; 当放电容量衰减为初始的 80% 时, 停止采样; 测试样本数量与验证样本数量保持不变。各特征数据熵权重如表 9 所示。

表 9 电池 B<sub>2</sub> 健康特征熵权重结果

Table 9 Entropy weight result of health feature of battery B<sub>2</sub>

健康特征	信息熵值/Nat	熵权重/%
峰高度 $y_{peak}$	0.994	50.525
峰位置 $x_{tel}$	0.956	23.203
瞬时压降幅值 $\Delta u_{ohm}$	0.969	26.272

将数据通过 GA-IBP 神经网络连续进行 5 次实验, 计及数据信息量的预测函数为

$$S_{OH_{pre\_B2}} = 0.2406 \cdot s_{oh\_predict}(Y_1) + 0.2714 \cdot s_{oh\_predict}(Y_2) + 0.2252 \cdot s_{oh\_predict}(Y_3) + 0.2628 \cdot s_{oh\_predict}(S_{EWM}) \quad (32)$$

基于式(32)对电池健康状态重新预测, 同时给出不同神经网络的预测结果, 如图 14 所示。各模型预测结果与实际值的误差情况如表 10 所示。

由表 10 可知, 对于电池 B<sub>2</sub>, 计及数据信息量

的电池健康状态预测模型的平均绝对误差与均方根误差分别为 0.63%、0.81%, 其预测结果同样均优于其他神经网络模型, 进一步证明了本文所提预测模型的有效性。

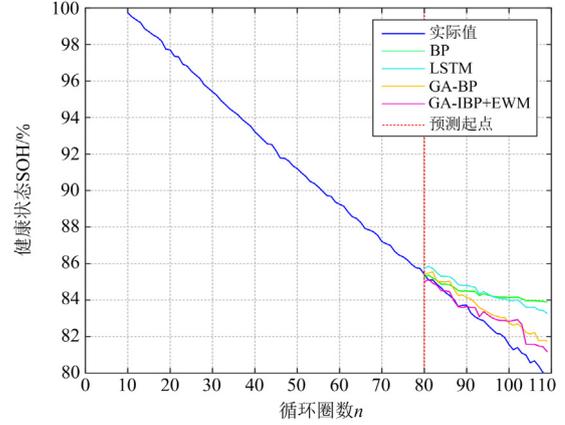


图 14 电池 B<sub>2</sub> 健康状态预测结果

Fig. 14 Prediction results of SOH of battery B<sub>2</sub>

表 10 电池 B<sub>2</sub> 健康状态预测误差统计

Table 10 Prediction error statistics of SOH of battery B<sub>2</sub>

预测模型	MAE/%	RMSE/%
BP	1.75	2.13
LSTM	1.79	2.00
GA-BP	0.89	1.01
GA-IBP+EWM	0.63	0.81

#### 4.2 剩余寿命预测

测试样本数量与验证样本数量保持不变, 基于计及特征数据信息量与健康状态预测结果的电池 B<sub>1</sub>、B<sub>2</sub> 剩余寿命预测函数分别为

$$R_{UL_{pre\_B1}} = 0.1622 \cdot r_{ul\_predict}(Y_1) + 0.1711 \cdot r_{ul\_predict}(Y_2) + 0.2180 \cdot r_{ul\_predict}(Y_3) + 0.1991 \cdot r_{ul\_predict}(R_{EWM}) + 0.2496 \cdot r_{ul\_predict}(R_{SOH}) \quad (33)$$

$$R_{UL_{pre\_B2}} = 0.1655 \cdot r_{ul\_predict}(Y_1) + 0.2582 \cdot r_{ul\_predict}(Y_2) + 0.1466 \cdot r_{ul\_predict}(Y_3) + 0.2130 \cdot r_{ul\_predict}(R_{EWM}) + 0.2168 \cdot r_{ul\_predict}(R_{SOH}) \quad (34)$$

基于式(33)、式(34)对电池剩余寿命进行重新预测, 各神经网络模型预测结果如图 15 所示。各模型预测结果与实际值的误差情况如表 11 所示。

由表 11 可以看出, 对于电池 B<sub>1</sub>、B<sub>2</sub>, 计及数据信息量的电池健康状态预测模型的平均绝对误差分别为 0.0027、0.0035 mA·h, 均方根误差分别为 0.0031、0.0042 mA·h, 均优于 BP、LSTM 多输入单神经网络及 GA-BP 优化神经网络的预测结果。

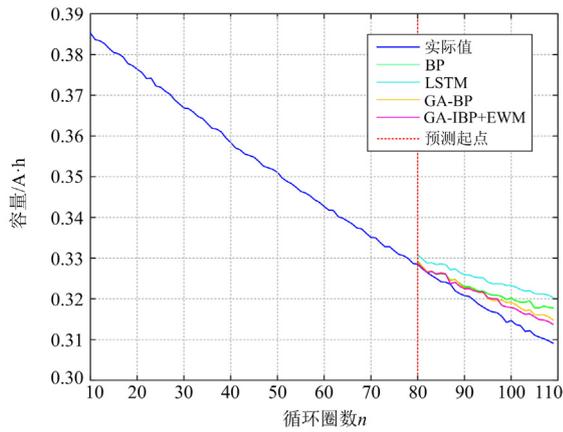
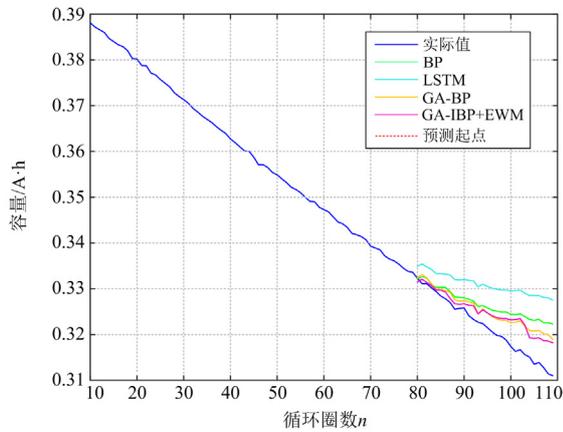
(a) 电池B<sub>1</sub>剩余寿命预测结果(b) 电池B<sub>2</sub>剩余寿命预测结果

图 15 各电池剩余寿命预测结果

Fig. 15 Prediction results of RUL of batteries

表 11 各电池剩余寿命预测误差统计

Table 11 Prediction error statistics of RUL of batteries

电池序号	预测模型	MAE/(mA·h)	RMSE/(mA·h)
B <sub>1</sub>	BP	0.0040	0.0048
	LSTM	0.0068	0.0074
	GA-BP	0.0032	0.0036
	GA-IBP+EWM	0.0027	0.0031
B <sub>2</sub>	BP	0.0050	0.0060
	LSTM	0.0073	0.0081
	GA-BP	0.0039	0.0045
	GA-IBP+EWM	0.0035	0.0042

## 5 结论

本文在 GA-BP 神经网络的基础上, 构建计及数据信息有效性的动量因子, 通过信息有效值来实现权重迭代速度的调整; 同时选择能够表征电池状态的健康特征作为输入, 提出一种计及健康特征信息量的加权神经网络电池健康状态与剩余寿命联合预

测模型, 基于熵权思想来过滤低信息量的健康特征预测结果, 来实现电池 SOH 与 RUL 的准确估计。

1) 采用 GA-BP 算法可以优化神经网络初始权重阈值, 为保证收敛速率, 本文对 GA-BP 进行改进, 提出一个计及数据信息有效性动量因子, 保证低信息量数据的迭代收敛速度。

2) 本文提出的方法对不同种类的电池都体现出较好的预测能力。基于网上公开的电池老化数据, 健康状态预测结果 MAE、RMSE 分别在 0.47%、0.69%之内, 剩余寿命预测结果 MAE、RMSE 分别在 0.0211、0.0269 A·h 之内; 基于实验平台 B<sub>1</sub>、B<sub>2</sub> 电池老化数据, 健康状态预测结果 MAE、RMSE 分别在 0.37%、0.42%和 0.63%、0.81%之内, 剩余寿命预测结果 MAE、RMSE 分别在 0.0027、0.0035 mA·h 和 0.0031、0.0042 mA·h 之内; 预测误差均优于多输入单神经网络与优化神经网络的预测结果, 预测误差较小。

在实际工程中, 储能系统监测对象是多样的, 确定最大因果关系的健康特征和实现最高数据质量的模型输入数据集是最关键的, 这也是接下来需要进一步研究的重点, 后期将开展相应研究, 为现有电池运行状态的有效监测提供依据。

## 参考文献

- [1] 赵冬梅, 徐辰宇, 陶然, 等. 多元分布式储能在新电力系统配电侧的灵活调控研究综述[J]. 中国电机工程学报, 2023, 43(5): 1776-1799.  
ZHAO Dongmei, XU Chenyu, TAO Ran, et al. Review on flexible regulation of multiple distributed energy storage in distribution side of new power system[J]. Proceedings of the CSEE, 2023, 43(5): 1776-1799.
- [2] XIONG R, LI L, TIAN J. Towards a smarter battery management system: a critical review on battery state of health monitoring methods[J]. Journal of Power Sources, 2018, 405: 18-29.
- [3] BERECIBAR M, GANDIAGA I, VILLARREAL I, et al. Critical review of state of health estimation methods of li-ion batteries for real applications[J]. Renewable and Sustainable Energy Reviews, 2016, 56: 572-587.
- [4] 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 Junyan, XIA Mingchao, CHEN Qifang. 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.

- [5] 邓子豪, 夏向阳, 张嘉诚. 磷酸铁锂电池优化多因子状态在线评估方法[J]. 电网与清洁能源, 2022, 38(3): 90-96.  
DENG Zihao, XIA Xiangyang, ZHANG Jiacheng. An optimized multi-factor online assessment method of SOH for LiFePO<sub>4</sub> batteries[J]. Power Systems and Clean Energy, 2022, 38(3): 90-96.
- [6] 刘大同, 宋宇晨, 武巍, 等. 锂离子电池组健康状态估计综述[J]. 仪器仪表学报, 2020, 41(11): 1-18.  
LIU Datong, SONG Yuchen, WU Wei, et al. Review of state of health estimation for lithium-ion battery pack[J]. Journal of Instrumentation, 2020, 41(11): 1-18.
- [7] 董鹏, 张剑波, 王震坡. 基于电化学阻抗谱的锂离子电池析锂检测方法[J]. 汽车安全与节能学报, 2021, 12(4): 570-579.  
DONG Peng, ZHANG Jianbo, WANG Zhenpo. Lithium plating identification based on electrochemical impedance spectra of lithium ion batteries[J]. Journal of Automotive Safety and Energy, 2021, 12(4): 570-579.
- [8] 陈息坤, 孙冬, 陈小虎. 锂离子电池建模及其荷电状态鲁棒估计[J]. 电工技术学报, 2015, 30(15): 141-147.  
CHEN Xikun, SUN Dong, CHEN Xiaohu. Modeling and state of charge robust estimation for lithium-ion batteries[J]. Transactions of China Electrotechnical Society, 2015, 30(15): 141-147.
- [9] 孙冬, 许爽. 梯次利用锂电池健康状态预测[J]. 电工技术学报, 2018, 33(9): 2121-2129.  
SUN Dong, XU Shuang. State of health prediction of second-use lithium-ion battery[J]. Transactions of China Electrotechnical Society, 2018, 33(9): 2121-2129.
- [10] WAAG W, KBITZ S, SAUER D U. Experimental investigation of the lithium-ion battery impedance characteristic at various conditions and aging states and its influence on the application[J]. Applied Energy, 2013, 102: 885-897.
- [11] 孙丙香, 苏晓佳, 马仕昌, 等. 基于低频阻抗谱和健康特征融合的锂离子电池健康状态主动探测方法研究[J]. 电力系统保护与控制, 2022, 50(7): 23-30.  
SUN Bingxiang, SU Xiaojia, MA Shichang, et al. An active detection method of li-ion battery health state based on low-frequency EIS and health feature fusion[J]. Power System Protection and Control, 2022, 50(7): 23-30.
- [12] CALBOREAN A, BRUJ O, MURARIU T, et al. Resonance frequency analysis of lead-acid cells: an EIS approach to predict the state-of-health[J]. Journal of Energy Storage, 2020, 27.  
of li-ion batteries[J]. Journal of Energy Storage, 2021, 40.
- [14] WANG S, FERNANDEZ C, FAN Y, et al. A novel safety assurance method based on the compound equivalent modeling and iterate reduce particle-adaptive Kalman filtering for the unmanned aerial vehicle lithium ion batteries[J]. Energy Science & Engineering, 2020, 8(5): 1-17.
- [15] DU J, LIU Z, WANG Y, et al. An adaptive sliding mode observer for lithium-ion battery state of charge and state of health estimation in electric vehicles[J]. Control Engineering Practice, 2016, 54: 81-90.
- [16] ZHANG S, GUO X, ZHANG X. Modeling of back-propagation neural network based state-of-charge estimation for lithium-ion batteries with consideration of capacity attenuation[J]. Advances in Electrical and Computer Engineering, 2019, 19(3): 3-10.
- [17] 何复兴. 基于数据驱动的锂离子电池荷电状态及健康状态估计研究[D]. 西安: 西安理工大学, 2021.  
HE Fuxing. Research on estimation state of charge and health of lithium-ion battery based on data-driven[D]. Xi'an: Xi'an University of Technology, 2021.
- [18] 黎冲, 王成辉, 王高, 等. 基于数据驱动的锂离子电池健康状态估计技术[J]. 中国电力, 2022, 55(8): 73-86, 95.  
LI Chong, WANG Chenghui, WANG Gao, et al. Research on online monitoring method of battery cluster inconsistency based on ohmic internal resistance voltage drop[J]. Electric Power, 2022, 55(8): 73-86, 95.
- [19] 贾俊, 胡晓松, 邓忠伟, 等. 数据驱动的锂离子电池健康状态综合评分及异常电池筛选[J]. 机械工程学报, 2021, 57(14): 141-149, 159.  
JIA Jun, HU Xiaosong, DENG Zhongwei, et al. Data-driven comprehensive evaluation of lithium-ion battery state of health and abnormal battery screening[J]. Journal of Mechanical Engineering, 2021, 57(14): 141-149, 159.
- [20] 冯海林, 张翀. 基于新健康因子的锂电池健康状态估计和剩余寿命预测[J]. 南京大学学报(自然科学), 2021, 57(4): 660-670.  
FENG Hailin, ZHANG Xuan. State of health estimation and remaining using life prediction of lithium-ion batteries based on new health indicators[J]. Journal of Nanjing University (Natural Science), 2021, 57(4): 660-670.
- [21] 徐佳宁, 倪裕隆, 朱春波. 基于改进支持向量回归的锂电池剩余寿命预测[J]. 电工技术学报, 2021, 36(17): 3693-3704.  
XU Jianing, NI Yulong, ZHU Chunbo. Remaining useful life prediction for lithium-ion batteries based on improved support vector regression[J]. Transactions of China Electrotechnical Society, 2021, 36(17): 3693-3704.
- [13] LIU X, LI K, WU J, et al. An extended Kalman filter based data-driven method for state of charge estimation

- [22] 王萍, 范凌峰, 程泽. 基于健康特征参数的锂离子电池 SOH 和 RUL 联合估计方法[J]. 中国电机工程学报, 2022, 42(4): 1523-1534.  
WANG Ping, FAN Lingfeng, CHENG Ze. A joint state of health and remaining useful life estimation approach for lithium-ion batteries based on health factor parameter[J]. Proceedings of the CSEE, 2022, 42(4): 1523-1534.
- [23] GOGOANA R, PINSON B, BAZANT Z, et al. Internal resistance matching for parallel-connected lithium-ion cells and impacts on battery pack cycle life[J]. Journal of Power Sources, 2014, 252: 8-13.
- [24] 周岷, 宋显华, 卢文斌, 等. 基于日常片段充电数据的锂电池健康状态实时评估方法研究[J]. 中国电机工程学报, 2019, 39(1): 105-111, 325.  
ZHOU Di, SONG Xianhua, LU Wenbin, et al. Real-time SOH estimation algorithm for lithium-ion batteries based on daily segment charging data[J]. Proceedings of the CSEE, 2019, 39(1): 105-111, 325.
- [25] 杨胜杰, 罗冰洋, 王菁, 等. 基于容量增量曲线峰值区间特征参数的锂离子电池健康状态估算[J]. 电工技术学报, 2021, 36(11): 2277-2287.  
YANG Shengjie, LUO Bingyang, WANG Jing, et al. State of health estimation for lithium-ion batteries based on peak region feature parameters of incremental capacity curve[J]. Transactions of China Electrotechnical Society, 2021, 36(11): 2277-2287.
- [26] 耿萌萌, 范茂松, 杨凯, 等. 基于 EIS 和神经网络的退役电池 SOH 快速估计[J]. 储能科学与技术, 2022, 11(2): 673-678.  
GENG Mengmeng, FAN Maosong, YANG Kai, et al. Fast estimation method for state-of-health of retired batteries based on electrochemical impedance spectroscopy and neural network[J]. Energy Storage Science and Technology, 2022, 11(2): 673-678.
- [27] 韦海燕, 陈孝杰, 吕治强, 等. 灰色神经网络模型在线估算锂离子电池 SOH[J]. 电网技术, 2017, 41(12): 4038-4044.  
WEI Haiyan, CHEN Xiaojie, LÜ Zhiqiang, et al. Grey neural network model for online estimation of lithium ion battery SOH[J]. Power System Technology, 2017, 41(12): 4038-4044.
- [28] 戴彦文, 于艾清. 基于健康特征参数的 CNN-LSTM&GRU 组合锂电池 SOH 估计[J]. 储能科学与技术, 2022, 11(5): 1641-1649.  
DAI Yanwen, YU Aiqing. Combined CNN-LSTM and GRU based health feature parameters for lithium-ion batteries SOH estimation[J]. Energy Storage Science and Technology, 2022, 11(5): 1641-1649.
- [29] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池 SOH 估算[J]. 电工技术学报, 2020, 35(19): 4106-4119.  
LI Chaoran, XIAO Fei, FAN Yaxiang, et al. An approach to lithium-ion battery SOH estimation based on convolutional neural network[J]. Transactions of China Electrotechnical Society, 2020, 35(19): 4106-4119.
- [30] 郭永芳, 黄凯, 李志刚. 基于短时搁置端电压压降的快速锂离子电池健康状态预测[J]. 电工技术学报, 2019, 34(19): 3968-3978.  
GUO Yongfang, HUANG Kai, LI Zhigang. Fast state of health prediction of lithium-ion battery based on terminal voltage drop during rest for short time[J]. Transactions of China Electrotechnical Society, 2019, 34(19): 3968-3978.
- [31] 黄健, 李建林, 李征. 退役锂离子电池健康状态快速评估方法[J]. 电力系统保护与控制, 2021, 49(12): 25-32.  
HUANG Jian, LI Jianlin, LI Zheng. A state of health rapid assessment method for decommissioned lithium-ion batteries[J]. Power System Protection and Control, 2021, 49(12): 25-32.
- [32] 严干贵, 李洪波, 段双明, 等. 基于模型参数辨识的储能电池状态估算[J]. 中国电机工程学报, 2020, 40(24): 8145-8154, 8251.  
YAN Gangui, LI Hongbo, DUAN Shuangming, et al. Energy storage battery state estimation based on model parameter identification[J]. Proceedings of the CSEE, 2020, 40(24): 8145-8154, 8251.
- [33] 晋殿卫, 顾则宇, 张志宏. 锂电池健康度和剩余寿命预测算法研究[J]. 电力系统保护与控制, 2023, 51(1): 122-130.  
JIN Dianwei, GU Zeyu, ZHANG Zhihong. Lithium battery health degree and residual life prediction algorithm[J]. Power System Protection and Control, 2023, 51(1): 122-130.
- [34] 姚和友. 遗传算法与改进的 BP 神经网络融合的三元锂电池 SOC 估算研究[D]. 南昌: 南昌大学, 2019.  
YAO Heyou. Study on SOC estimation of ternary lithium battery based on genetic algorithms and improved BP neural network[D]. Nanchang: Nanchang University, 2019.

收稿日期: 2023-05-23; 修回日期: 2023-06-30

作者简介:

岳家辉(1994—), 男, 博士研究生, 研究方向为储能安全运行与控制; E-mail: 243952600@qq.com

夏向阳(1968—), 男, 通信作者, 博士, 教授, 研究方向为柔性直流输电控制和储能安全控制等。E-mail: 307351045@qq.com

(编辑 姜新丽)