

DOI: 10.19783/j.cnki.pspc.250733

# 基于充电曲线及 GA-LM-BP 网络的锂电池 SoH 估计

郭向伟<sup>1,2</sup>, 李文静<sup>1</sup>, 袁江龙<sup>1</sup>, 钱伟<sup>1,2</sup>, 赵良军<sup>1</sup>

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

**摘要:** 锂电池健康状态(state of health, SoH)不仅直接影响荷电状态的准确估计, 还关系到电池整个生命周期的安全运行, 其精确估计是锂电池应用领域的核心问题。针对基于数据驱动的 SoH 估计方法存在泛化能力弱、估计精度低的不足, 提出一种基于充电曲线和改进反向传播(back propagation, BP)神经网络的锂电池 SoH 估计方法。首先, 基于恒流充电曲线, 设计等充电电压差时间间隔(time interval for equal charging voltage difference, TI-ECVD)作为健康特征, 以模拟随机恒流充电片段, 简化 SoH 估计模型的输入参数。其次, 结合 BP 网络结构简单的特点, 在 BP 网络基础上加入遗传算法(genetic algorithm, GA)并引入莱文伯格-马夸特(levenberg-marquardt, LM)算法, 提出 GA-LM-BP 网络结构, GA 算法用以降低 BP 网络陷入局部最优解的概率, LM 算法则用于提高 BP 网络的收敛速度。最后, 基于自主实验平台测试数据搭建 SoH 估计模型, 通过与同类型估计方法的对比分析, 表明了所提估计方法在估计精度与运行速度方面的优势。

**关键词:** 锂电池; 健康状态; 等充电电压差时间间隔; 充电曲线; GA-LM-BP 网络

## State of health estimation of lithium-ion batteries based on charging curves and GA-LM-BP network

GUO Xiangwei<sup>1,2</sup>, LI Wenjing<sup>1</sup>, YUAN Jianglong<sup>1</sup>, QIAN Wei<sup>1,2</sup>, ZHAO Liangjun<sup>1</sup>

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China;  
2. Henan Key Laboratory of Intelligent Detection and Control of Coal Mine Equipment, Jiaozuo 454003, China)

**Abstract:** The state of health (SoH) of lithium-ion batteries not only directly affects the accuracy of the state of charge estimation, but is also closely related to the safe operation throughout the battery lifecycle. Accurate SoH estimation is therefore a core issue in lithium-ion battery applications. To address the limitations of data-driven SoH estimation methods, such as poor generalization ability and low estimation accuracy, a lithium-ion battery SoH estimation method based on charging curves and an improved Backpropagation (BP) neural network is proposed. First, based on the constant-current charging curves, a health feature termed the time interval for equal charging voltage difference (TI-ECVD) is designed to simulate random constant-current charging segments, thereby simplifying the input parameters of the SoH estimation model. Second, leveraging the simple structural of the BP network, a genetic algorithm (GA) and the Levenberg-Marquardt (LM) algorithm are incorporated to form a GA-LM-BP network. The GA is used to mitigate the risk of the BP network falling into local optima, while the LM algorithm improves its convergence speed. Finally, based on test data from an autonomous experimental platform, a SoH estimation model is constructed. Comparative analysis with similar estimation methods demonstrates that the proposed method achieves superior performance in both estimation accuracy and computational efficiency.

This work is supported by the National Natural Science Foundation of China (No. 62373137).

**Key words:** lithium-ion battery; state of health; time interval for equal charging voltage difference; charging curve; GA-LM-BP network

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

## 0 引言

锂电池因其能量密度高、自放电率低等特点, 被广泛应用于电动汽车和电网储能系统等领域<sup>[1-3]</sup>。随着使用时间的增加, 锂电池不可避免地出现容量衰减、内阻增加以及热稳定性下降等情况, 导致能量利用率降低, 严重时甚至引发安全事故<sup>[4-7]</sup>。锂电池健康状态(state of health, SoH)作为评估电池老化程度的关键参数, 其精确估计能够有效减少潜在的安全风险, 已成为当前锂电池研究的热点<sup>[8-9]</sup>。

目前, 锂电池 SoH 估计方法主要集中于模型法和数据驱动法<sup>[10-12]</sup>。模型法通过研究电池内部行为构建电化学模型, 以达到对 SoH 的估计。模型法往往需要复杂的数学计算, 且对模型参数具有很高的依赖性, 而精确获取时变且多因素耦合的模型参数较为困难。数据驱动法通过神经网络建立特征参数与 SoH 的映射关系以达到对 SoH 的估计<sup>[13]</sup>。数据驱动法因其无需精确了解电池复杂的内部机理, 避免了对内部参数的高度依赖性, 而被广泛应用<sup>[14-15]</sup>。基于数据驱动法的 SoH 估计, 关键影响因素在于健康特征及神经网络结构的设计。

针对锂电池健康特征, 众多学者进行了深入的研究。文献[16]从全电压范围和部分电压范围提取 568 组健康特征, 利用 4 种算法进行特征选择, 将不重要的特征权重设为 0, 对选出的特征按重要性排序并赋予权重, 最后排除相似程度高的一组特征后用剩余数据训练模型。文献[17]通过充电曲线提取多个非均质特征, 采用灰色相关分析选取对 SoH 映射能力较强的特征, 并结合深度高斯过程回归模型来估计 SoH。以上文献中 SoH 估计模型的输入依赖于完整的充电曲线, 模型输入参数复杂; 同时, 文献所提取的健康特征种类较多, 增加了神经网络计算量。文献[18]基于增量容量(incremental capacity, IC)曲线, 探讨不同电压范围内 IC 对 SoH 的映射能力。文献[19]基于充电电压曲线的重构获取无干扰的差分时间曲线, 并结合网格搜索优化方法确定最佳充电电压窗口以提取健康特征。以上文献的方法虽取得了较高的 SoH 估计精度, 但模型输入均局限于固定电压范围的充电曲线, 导致模型泛化能力一般。

也有学者将研究重点放在神经网络结构的设计。反向传播(back propagation, BP)神经网络因其灵活的网络结构和强大的非线性映射能力被广泛应用<sup>[20]</sup>。文献[21]借助 BP 神经网络分析 IC 曲线特性与电池 SoH 的相关性, 从而实现不同温度下的 SoH 估计。基础 BP 神经网络存在收敛速度慢、易陷入局部最优解等不足。为提升 BP 神经网络性能, 文献[22]

通过遗传算法(genetic algorithm, GA)选取 BP 神经网络的最优初始权阈值, 发挥全局寻优作用, 进而实现高精度的 SoH 估计。引入 GA 算法虽然提高了 BP 网络的估计精度, 但增加了网络的复杂程度, 导致模型运行时间增加。文献[23]提出在基于自适应 GA 算法的 BP 神经网络中增加反正切函数, 促使 GA 算法的交叉概率和突变概率稳定变化, 以避免陷入局部最优和收敛困难, 但未考虑网络在更新权阈值时也易陷入局部最小值的问题, 导致估计精度受限。

基于以上分析, 较多学者对基于数据驱动的锂电池 SoH 估计开展了深入研究, 提高了其适用范围和估计精度, 但仍存在模型输入为固定电压范围而导致的的应用范围受限及网络结构表征能力不足的现象。针对以上问题, 首先基于恒流充电曲线, 设计等充电电压差时间间隔(time interval for equal charging voltage difference, TI-ECVD)作为健康特征, 以模拟随机恒流充电片段, 简化 SoH 估计模型的输入参数。其次, 结合 BP 网络结构简单的特点, 在 BP 网络基础上加入 GA 算法并引入莱文伯格-马夸特(levenberg-marquardt, LM)算法, 提出 GA-LM-BP 网络结构, GA 算法用以降低 BP 神经网络陷入局部最优解的概率, LM 算法则用于提高 BP 神经网络的收敛速度。具体创新点体现在:

- 1) SoH 估计模型的输入可以为任意恒流充电片段的起止电压和电流, 减小了模型输入参数的限制, 使得估计方法适用性更强。
- 2) 基于 BP 神经网络引入 GA 算法和 LM 算法, 通过寻找最优初始权阈值和改进权阈值更新机制使网络快速收敛至全局最优解, 提高估计模型精度和运行速度。

## 1 SoH 特征参数设计

本节基于对充电曲线的分析, 设计 TI-ECVD 作为健康特征。

### 1.1 恒流充电曲线

充电曲线获取实验采用松下 NCR18650GA 三元锂电池, 具体参数如表 1 所示。实验平台由上位机、可编程电子负载、高低温试验箱组成, 如图 1 所示。其中, 测试误差小于 0.05%, 采样频率设定为 2 Hz, 实验温度设定为 25 °C。

实验过程中, 恒流充电数据采集实验与循环老化实验交替进行。其中, 恒流充电数据采集实验用于获取不同倍率的完整恒流充电曲线, 选择 0.2C、0.5C、0.75C 和 1C 等 4 种常见倍率作为充电电流。而循环老化实验旨在缩短实验时间, 以获取电池在不同 SoH 下的恒流充电数据。实验步骤如图 2 所示。

表 1 电池参数

Table 1 Lithium battery parameters

参数	数值
容量/mAh	3500
标称电压/V	3.6
充放电截止电压/V	4.2/2.5
内阻/mΩ	<38

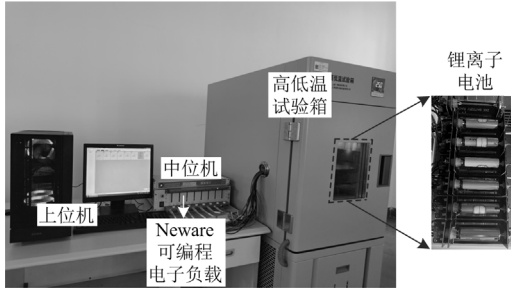


图 1 电池测试平台

Fig. 1 Platform for battery testing

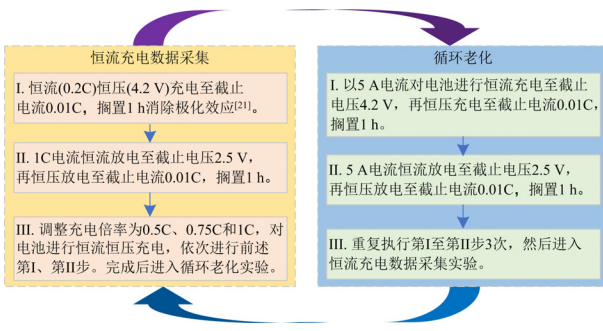


图 2 实验步骤

Fig. 2 Experimental procedure

实验过程中 SoH 定义为一次充放电循环中充电容量、放电容量的平均值与电池额定容量的比值，如式(1)所示。

$$Y_{\text{SoH}} = \frac{C_{\text{charge}} + C_{\text{discharge}}}{2C_{\text{rated}}} \quad (1)$$

式中： $Y_{\text{SoH}}$  为电池 SoH 值； $C_{\text{charge}}$  和  $C_{\text{discharge}}$  分别为一次充放电过程中的充电容量和放电容量； $C_{\text{rated}}$  为额定容量。

当 SoH 较高或较低时，充电曲线的差异更为显著，与健康特征之间的映射关系也更加明确<sup>[24]</sup>。若估计方法能够在充电曲线差异不明显的阶段仍取得较好的估计结果，那么理论上该方法在整个电池老化过程中将展现出更高的估计精度。本文选择在 SoH 为[0.88,0.96]的范围内进行新型估计方法的设计。在此范围内，SoH 每间隔 0.01 提取出一组不同充电倍率曲线获取健康特征。如图 3 所示为以 1C 倍率为例的 9 条恒流充电曲线。

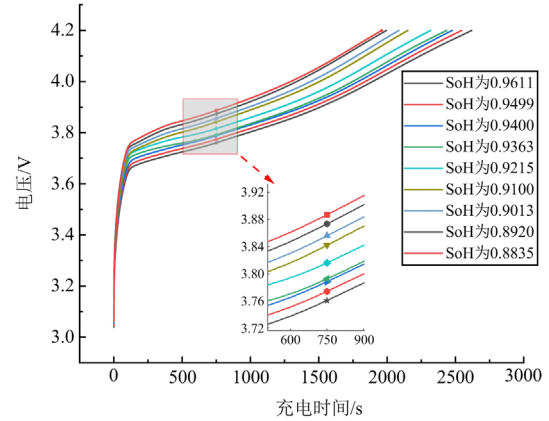


图 3 1C 倍率恒流充电曲线

Fig. 3 Constant-current charging curves at 1C charging current

### 1.2 特征参数

本文选取 SoH 为 0.96、0.94、0.92、0.90 和 0.88 时的恒流充电数据，完成模型特征参数标定。基于恒流充电曲线，设计 TI-ECVD 作为健康特征。设计思路为：针对各个 SoH 下的不同充电倍率，将锂电池电压从 4.2 V 至充电起始电压以 10 mV 为单位压差进行划分。电池电压 4.2 V 时对应的时刻为初始零时刻；电池电压 4.19 V 时，不同倍率条件下对应的时刻分别为  $t_{0.2c,1}$ 、 $t_{0.5c,1}$ 、 $t_{0.75c,1}$ 、 $t_{1c,1}$ …。当电压为充电起始电压时，0.2C、0.5C、0.75C 和 1C 对应的时刻分别为  $t_{0.2c,q}$ 、 $t_{0.5c,s}$ 、 $t_{0.75c,z}$ 、 $t_{1c,c}$ 。以此类推，建立不同 SoH 条件下不同倍率的充电数据集。以 4.2 V 电压对应零时刻的原因在于：不同充电倍率对应的起始电压不一致，但充电截止电压均为 4.2 V，为规范数据标签，统一将 4.2 V 对应零时刻。由于锂电池具有极化效应，在相同 SoH 下，充电倍率越大，电池内部的极化现象越明显<sup>[25]</sup>，起始电压越高，因此  $t_{0.2c,q} > t_{0.5c,s} > t_{0.75c,z} > t_{1c,c}$ 。表 2 所示为各 SoH 条件下健康特征对应的数据集。

表 2 各 SoH 条件下数据集

Table 2 Dataset of each SoH

电压/V	不同倍率对应的相对时刻			
	0.2C	0.5C	0.75C	1C
4.20	0	0	0	0
4.19	$t_{0.2c,1}$	$t_{0.5c,1}$	$t_{0.75c,1}$	$t_{1c,1}$
...	...	...	...	...
起始电压(1C)	...	...	...	$t_{1c,c}$
...	...	...	...	...
起始电压(0.75C)	...	...	$t_{0.75c,z}$	...
...	...	...	...	...
起始电压(0.5C)	...	$t_{0.5c,s}$	...	...
...	...	...	...	...
起始电压(0.2C)	$t_{0.2c,q}$	...	...	...

为探究新型健康特征和目前常见健康特征与 SoH 的相关程度, 从 18 条 0.2C 和 0.5C 恒流充电倍率的老化曲线中提取健康特征, 采用皮尔逊系数作为特征相关性评价标准<sup>[26]</sup>。

提取常见的恒流充电时间(constant current charging time, CCCT)、恒流放电时间(constant current discharging time, CCDT)、单位放电时间的平均压降(average voltage difference for unit discharging time, AVD-UDT)和本文所提的 TI-ECVD 进行对比分析。CCCT 为电池从完全放电状态开始, 以恒定电流充电, 直至电压达到充电截止电压时所用的时间。CCDT 为电池从完全充满的状态开始, 恒流放电至截止电压所用的时间。AVD-UDT 为放电期间总压降与总时间的比值。TI-ECVD 为电压区间的起始电压与结束电压所对应的时间间隔。为探究不同电压区间 TI-ECVD 与 SoH 的相关性, 且鉴于不同充电倍率及不同 SoH 状态下充电曲线起始电压存在差异, 选取测试数据共同覆盖的电压区间, 将其划分为 3.30~3.60 V、3.60~3.90 V 和 3.90~4.20 V 共 3 个子区间, 以分别评估各区间内 TI-ECVD 与 SoH 的相关性。根据各健康特征的定义, 针对每个健康特征下的不同倍率, 从相应的老化曲线中提取特征值, 构建特征序列  $X = [X_1 X_2 \cdots X_n \cdots X_N]$ , 同时, 获取每个特征值所处老化曲线的 SoH 值, 构建 SoH

序列  $Y = [Y_{\text{SoH},1} Y_{\text{SoH},2} \cdots Y_{\text{SoH},n} \cdots Y_{\text{SoH},N}]$ 。基于特征序列和 SoH 序列, 利用如式(2)所示皮尔逊相关性公式, 计算不同充电倍率下各健康特征与 SoH 的相关性。

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{\sum_{n=1}^N (X_n - \bar{X})(Y_{\text{SoH},n} - \bar{Y})}{\sqrt{\sum_{n=1}^N (X_n - \bar{X})^2} \sqrt{\sum_{n=1}^N (Y_{\text{SoH},n} - \bar{Y})^2}} \quad (2)$$

式中:  $N$  为序列的长度;  $\bar{X}$  和  $\bar{Y}$  分别表示特征序列和 SoH 序列的平均值;  $\text{cov}(X, Y)$  表示特征序列和 SoH 序列的协方差;  $\sigma_X$  和  $\sigma_Y$  分别表示特征序列和 SoH 序列的标准差。各健康特征与 SoH 相关性系数计算过程及结果如图 4 所示。皮尔逊系数越趋近于 1, 特征与 SoH 之间的相关性越强。

由图 4 数据可知, 各电压区间的 TI-ECVD、CCCT 与 SoH 的相关性最高。在电池系统的实际充电过程中, 开始充电前往往存在剩余电量, 而充电结束时并不一定充到上限截止电压。这使得多数工况下, 较难获取完整的恒流充电时间。而 TI-ECVD 能够灵活地在不同局部电压区间提取数据, 具有良好的环境适应性。图 4 结果表明, 与常见的健康特征相比, 不同电压区间的 TI-ECVD 均与 SoH 的相关性更强, 且更容易获取。

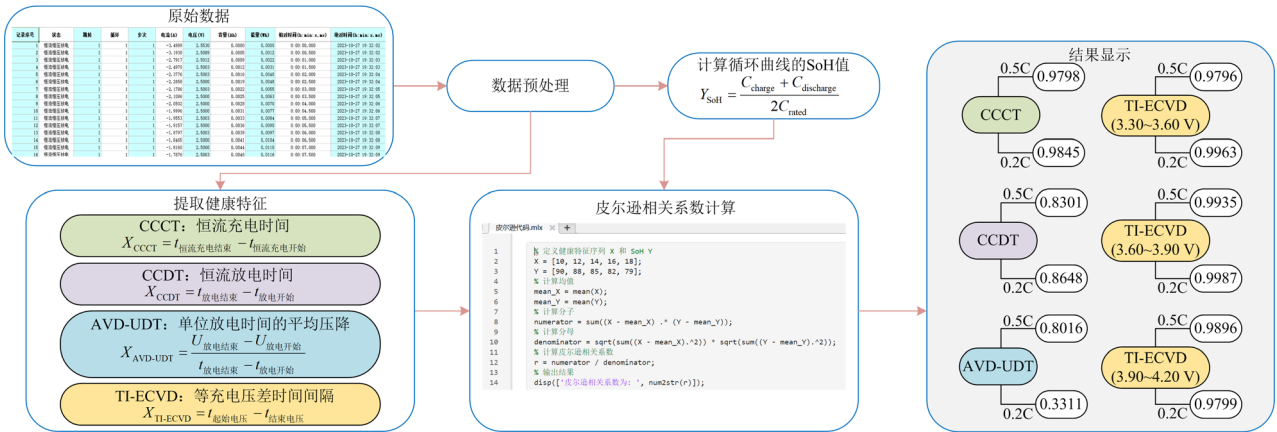


图 4 皮尔逊系数获取过程

Fig. 4 Process for obtaining Pearson correlation coefficient

## 2 基于 GA-LM 算法的 BP 神经网络设计

针对传统 BP 神经网络易陷入局部极小值、收敛速度慢的问题, 本文首先在 BP 算法中融合 LM 算法的阻尼因子调节机制, 通过动态调整权值和阈值的更新方向与步长, 提升网络收敛效率; 其次在 LM-BP 网络基础上引入 GA 算法, 利用其全局搜索能力对网络初始权值和阈值进行优化筛选, 降低模

型对初始参数的敏感性, 从而减少陷入局部最优解的概率。通过这两种算法的协同作用, 从模型训练前初始权阈值选取和训练过程中权阈值调整两方面提升模型的收敛稳定性和训练效率, 从而提高 SoH 估计精度。

### 2.1 基于 LM 算法改进 BP 神经网络

BP 神经网络虽然具有结构简单、收敛速度快等特点, 但训练过程中, 当误差曲面变得较为平坦

时,即使进行大幅度的权重更新,误差的减少也可能非常有限。用于求解非线性最小二乘问题的 LM 算法结合了梯度下降法的全局稳定性和牛顿法的快速收敛性。该算法通过引入阻尼因子,在优化过程中动态调整参数的更新方向和步长,既能在远离最优解时沿负梯度方向进行小步长保守更新,增强全局搜索能力,又能在接近最优解时利用雅可比矩阵的二次收敛特性进行大步长更新,快速逼近局部最优解<sup>[27]</sup>。本文通过引入 LM 算法以优化 BP 神经网络,提高网络学习效率和整体性能。

BP 神经网络由输入层、隐藏层和输出层组成,分为前向传播和反向传播两个阶段。设  $l$  为样本数量,  $O_i$  和  $Y_{\text{SoH},i}$  分别表示对应样本点  $i$  的期望输出和输出层输出。网络输出与期望值的误差定义为  $E$ 。

$$E = \frac{1}{2} \sum_{i=1}^l (O_i - Y_{\text{SoH},i})^2 \quad (3)$$

为实现误差最小化, BP 神经网络采用了梯度下降法对权阈值不断调整。梯度下降的数学形式为

$$\Delta \omega_{dj} = -\eta \frac{\partial E}{\partial \omega_{dj}} \quad (4)$$

$$\Delta \omega_{jb} = -\eta \frac{\partial E}{\partial \omega_{jb}} \quad (5)$$

式中:权重  $\omega_{dj}$  为输入层第  $d$  个神经元与隐含层第  $j$  个神经元之间的信号传递强度;权重  $\omega_{jb}$  为隐含层第  $j$  个神经元与输出层第  $b$  个神经元之间的信号传递强度;  $\eta$  为学习率。

基于 LM 算法对 BP 网络权阈值更新机制的优化可以确保在误差增大时,通过调整权阈值更新方向至误差最小化的方向,实现小步长的稳定收敛,纠正先前的更新方向偏差;而在误差减小时,维持当前正确的更新方向,加速权阈值的更新,从而加快网络的收敛速度。因此,基于 LM 算法改进的 BP 网络在训练过程中既保持了稳定且快速的学习速度,又减小了陷入局部最小值的可能性,提高了网络整体性能,从而提高了 SoH 的估计精度。LM 算法融合 BP 神经网络的推导过程如下所述。

设  $\mathbf{W} = [w_1 \ w_2 \ \dots \ w_M]^T$  是 BP 神经网络的权值向量,  $w_M$  为第  $M$  维度的权值向量,则

$$\mathbf{W}_{k+1} = \mathbf{W}_k + \Delta \mathbf{W} \quad (6)$$

式中:  $\mathbf{W}_k$  和  $\mathbf{W}_{k+1}$  分别表示第  $k$  次、第  $k+1$  次迭代的权值向量;  $\Delta \mathbf{W}$  表示权值向量在每次迭代中的更新量。设误差函数为

$$\mathbf{E}(\mathbf{W}) = \frac{1}{2} \sum_{i=1}^l e_i^2(\mathbf{W}) = \frac{1}{2} \mathbf{e}^T(\mathbf{W}) \mathbf{e}(\mathbf{W}) \quad (7)$$

式中:  $e_i(\mathbf{W})$  为 BP 神经网络在权重  $\mathbf{W}$  下样本点  $i$  处的输出与期望输出的误差,  $e_i(\mathbf{W}) = O_i - Y_{\text{SoH},i}$ ;  $\mathbf{e}(\mathbf{W})$  表示误差向量,具体形式如式(8)所示。

$$\mathbf{e}(\mathbf{W}) = [e_1(\mathbf{W}) \ e_2(\mathbf{W}) \ \dots \ e_l(\mathbf{W})]^T \quad (8)$$

依据牛顿法原理,网络权值迭代更新遵循式(9)。

$$\begin{cases} \mathbf{W}_{k+1} = \mathbf{W}_k + \Delta \mathbf{W} \\ \Delta \mathbf{W} = -(\mathbf{H}(\mathbf{W}))^{-1} \nabla \mathbf{E}(\mathbf{W}) \Big|_{\mathbf{W}=\mathbf{W}_k} \end{cases} \quad (9)$$

式中:  $\mathbf{H}(\mathbf{W})$  代表黑塞矩阵;  $\nabla \mathbf{E}(\mathbf{W})$  为误差梯度。

$$\nabla \mathbf{E}(\mathbf{W}) = \mathbf{J}^T(\mathbf{W}) \cdot \mathbf{e}(\mathbf{W}) \quad (10)$$

$$\mathbf{H}(\mathbf{W}) = \nabla^2 \mathbf{E}(\mathbf{W}) = \mathbf{J}^T(\mathbf{W}) \cdot \mathbf{J}(\mathbf{W}) + \mathbf{Q}(\mathbf{W}) \quad (11)$$

式中:  $\nabla^2 \mathbf{E}(\mathbf{W})$  表示误差函数关于所有权重  $\mathbf{W}$  的二阶偏导数矩阵;  $\mathbf{Q}(\mathbf{W}) = \sum_{i=1}^l e_i(\mathbf{W}) \nabla^2 e_i(\mathbf{W})$ , 其中  $\nabla^2 e_i(\mathbf{W})$  为第  $i$  个样本点处误差对权重的二阶导数;  $\mathbf{J}(\mathbf{W})$  为雅可比矩阵。  $\mathbf{J}(\mathbf{W})$  计算方法如式(12)所示。

$$\mathbf{J}(\mathbf{W}) = \begin{bmatrix} \frac{\partial e_1(\mathbf{W})}{\partial w_1} & \frac{\partial e_1(\mathbf{W})}{\partial w_2} & \dots & \frac{\partial e_1(\mathbf{W})}{\partial w_M} \\ \frac{\partial e_2(\mathbf{W})}{\partial w_1} & \frac{\partial e_2(\mathbf{W})}{\partial w_2} & \dots & \frac{\partial e_2(\mathbf{W})}{\partial w_M} \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_l(\mathbf{W})}{\partial w_1} & \frac{\partial e_l(\mathbf{W})}{\partial w_2} & \dots & \frac{\partial e_l(\mathbf{W})}{\partial w_M} \end{bmatrix} \quad (12)$$

迭代过程中,若  $\mathbf{H}(\mathbf{W})$  无法求逆,需对其变形,如式(13)所示。

$$\mathbf{H}(\mathbf{W}) \approx \mathbf{J}^T(\mathbf{W}) \cdot \mathbf{J}(\mathbf{W}) + \mu \cdot \mathbf{I} \quad (13)$$

式中:  $\mathbf{I}$  为单位矩阵;  $\mu$  为阻尼系数。经 LM 算法改进的 BP 神经网络权阈值调整公式为

$$\Delta \mathbf{W} = -[\mathbf{J}^T(\mathbf{W}) \cdot \mathbf{J}(\mathbf{W}) + \mu \cdot \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{W}) \cdot \mathbf{e}(\mathbf{W}) \Big|_{\mathbf{W}=\mathbf{W}_k} \quad (14)$$

$$\mathbf{W}_{k+1} = \mathbf{W}_k - [\mathbf{J}^T(\mathbf{W}) \cdot \mathbf{J}(\mathbf{W}) + \mu \cdot \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{W}) \cdot \mathbf{e}(\mathbf{W}) \Big|_{\mathbf{W}=\mathbf{W}_k} \quad (15)$$

为进一步凸显 LM 算法的优化性能,本文将阻尼因子与常数  $\beta$  相结合,进一步加快更新机制的速度和效率。当误差增大时,阻尼因子  $\mu$  增大,并通过乘以  $\beta$  进一步放大其变化,使算法更接近梯度下降法,从而加快更新方向的调整速度。当误差减小时,阻尼因子  $\mu$  减小,通过除以  $\beta$  进一步减小,使算法更接近牛顿法,进一步加快局部收敛速度。这一调整机制使得阻尼因子  $\mu$  更快放大或缩小,显著提高了阻尼因子调整步长时的效率。当常数  $\beta$  过大时易发散,  $\beta$  过小时收敛速度慢。为保证 LM 算法

兼具良好的收敛速度与稳定性, 本文采用了多阶段参数寻优策略以确定  $\beta$  的最优值。具体步骤为: 首先, 进行数量级测试 ( $\beta \in \{1, 10, 100\}$ ), 排除了收敛过慢 ( $\beta=1$ ) 及易发散 ( $\beta=100$ ) 的取值, 初步确认  $\beta=10$  时性能最佳; 随后进行边界测试 ( $\beta=5, 55$ ), 据此将有效参数范围缩小至  $[5, 55]$ ; 进而以步长 5

对该区间进行粗调寻优, 综合收敛速度与稳定性指标确定  $\beta=10$  为最优点; 最终, 在最优点区间  $[5, 15]$  内以步长 1 进行精调验证, 结果表明  $\beta=10$  在所有评估指标上均表现最佳。该过程有效避免了参数经验化和主观随机性, 本文最终取常数  $\beta=10$ 。具体 LM-BP 网络结构的设计流程如图 5 所示。

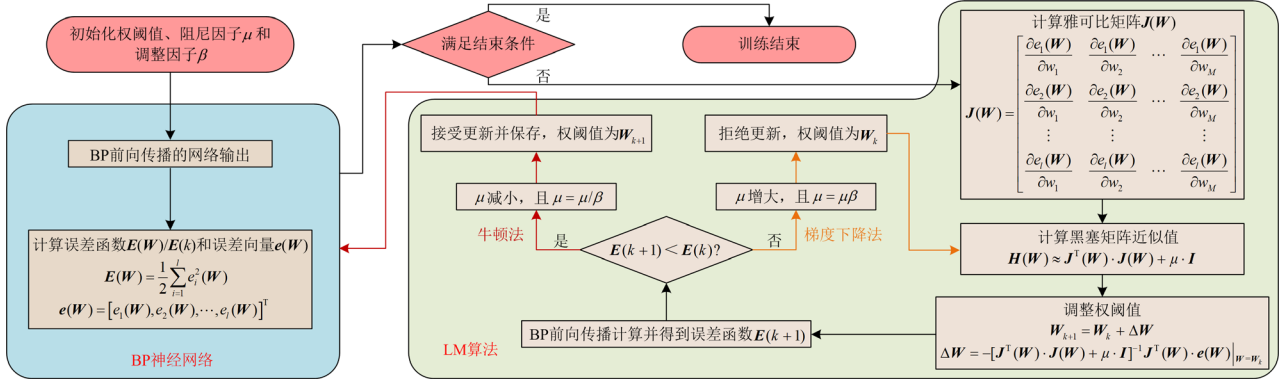


图 5 LM-BP 网络结构的设计流程图

Fig. 5 Flowchart for designing LM-BP network

## 2.2 GA-LM-BP 神经网络设计

LM-BP 网络在训练前由初始权阈值决定了参数空间的起始搜索点, 不同的初始值可能使网络收敛到不同的局部极小值。当取到较差的初始值时, 收敛时间显著延长, 甚至导致训练过程振荡。为解决此问题, 本文采用 GA 算法确定 LM-BP 网络的最优初始权阈值, 以提高网络估计的精度和收敛速度。GA 算法的核心优势在于可同时评估多个候选解, 弥补 LM 算法单点迭代的不足, 同时降低 LM-BP 网络对初始参数随机性的敏感度。GA-LM-BP 网络设计流程如图 6 所示。

针对 GA-LM-BP 网络的设计, 首先进行种群初始化, 随机生成初始种群, 其中每个个体代表一组可能的权阈值。其次, 通过适应度计算将每个个体的权阈值代入 LM-BP 神经网络。最后, 利用选择、交叉和变异操作迭代更新种群, 逐步筛选出适应度更高的个体。这一过程持续进行, 直到满足终止条件, 即达到最大遗传代数。获得最优初始权阈值后, 将其用于 LM-BP 神经网络的训练。

## 3 基于 GA-LM-BP 网络的 SoH 估计

本文估计方法包含离线训练和在线预测两个阶段。离线阶段, 基于第 1 节所设计的健康特征, 建立了 5 个不同 SoH 下的数据集。采用 GA-LM-BP 神经网络结构分别对 5 个数据集进行训练, 最终获得 5 个对应不同 SoH 的训练模型。在线预测阶段, 将任意恒流阶段电压片段的电流、起始电压和结束电压输入 5 个模型, 5 个模型分别输出开始电压和结束电压对应的相对时刻值, 基于相对时刻值求解 5 个模型对应的时间差。将 5 个模型时间差与实际时间差进行比较, 利用二分法估计实际时间差对应的 SoH。具体步骤如下所述, 实现过程如图 7 所示。

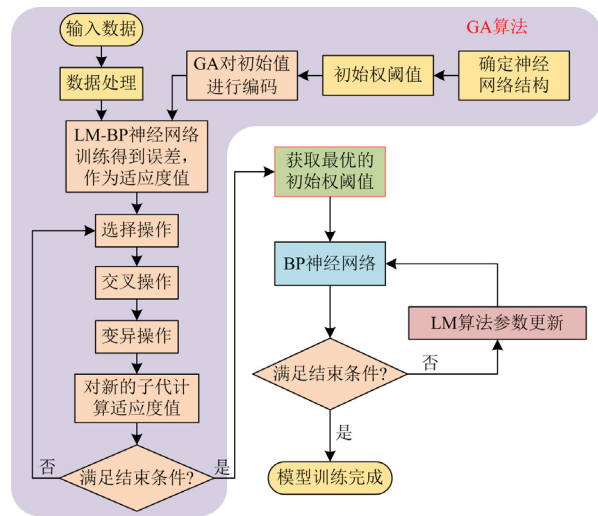


图 6 GA-LM-BP 神经网络估计流程

Fig. 6 Flowchart of estimation for GA-LM-BP neural network

1) 比较 5 个模型输出的时间差和实际时间差, 选取大于且最接近实际时间差的模型输出时间差记为  $X_{TI-ECVD,H}$ , 选取小于且最接近实际时间差的模型输出时间差记为  $X_{TI-ECVD,L}$ , 实际时间差记为  $X_{actual}$ 。

2) 通过二分法计算实测时间差对应的  $Y_{SoH, predict}$ 。

$$Y_{\text{SoH,predict}} = Y_{\text{SoH,L}} + \frac{X_{\text{actual}} - X_{\text{TI-ECVD,L}}}{X_{\text{TI-ECVD,H}} - X_{\text{TI-ECVD,L}}} (Y_{\text{SoH,H}} - Y_{\text{SoH,L}}) \quad (16)$$

式中:  $Y_{\text{SoH,H}}$ 、 $Y_{\text{SoH,L}}$  分别为  $X_{\text{TI-ECVD,H}}$ 、 $X_{\text{TI-ECVD,L}}$  对应的模型标定值。

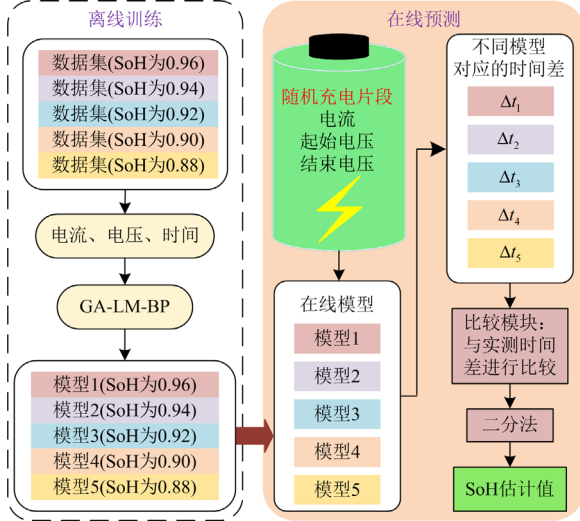


图 7 基于 GA-LM-BP 网络的 SoH 估计

Fig. 7 SoH estimation based on GA-LM-BP network

#### 4 SoH 估计性能分析

在 MATLAB(2024b)中搭建预测模型以进行 SoH 估计性能分析。采用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和误差标准差(standard deviation of error, SDE)作为评价指标。各指标计算公式分别如式(17)一式(19)所示。

$$e_{\text{MAE}} = \frac{1}{P} \sum_{p=1}^P |O_p - Y_{\text{SoH},p}| \quad (17)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{P} \sum_{p=1}^P (O_p - Y_{\text{SoH},p})^2} \quad (18)$$

$$e_{\text{SDE}} = \sqrt{\frac{1}{P} \sum_{p=1}^P (e_p - \bar{e})^2} \quad (19)$$

式中:  $P$  为评估的样本数量;  $O_p$  和  $Y_{\text{SoH},p}$  分别表示在时间步长  $p$  时, 模型输出的估计值和实际值。在时间步长  $p$  时的误差  $e_p$  和样本误差平均值  $\bar{e}$  为

$$e_p = O_p - Y_{\text{SoH},p} \quad (20)$$

$$\bar{e} = \frac{1}{P} \sum_{p=1}^P e_p \quad (21)$$

基于 GA-LM-BP 网络的 SoH 估计步骤如图 8 所示。

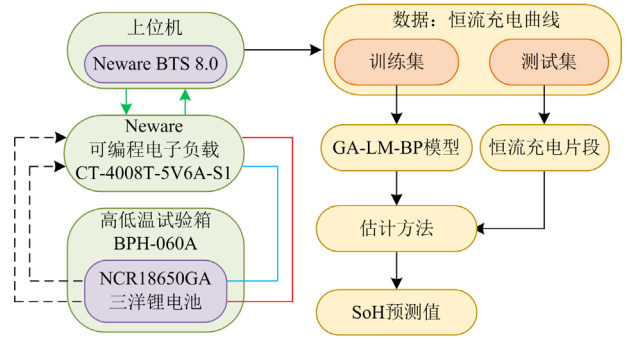


图 8 基于 GA-LM-BP 网络估计 SoH 流程


Fig. 8 Flowchart for estimating SoH with GA-LM-BP network

首先, 利用上位机驱动可编程电子负载对锂电池进行充放电实验, 并采集实验数据; 随后, 将预处理后的恒流充电片段划分为训练集与测试集; 接着, 通过训练集数据对 GA-LM-BP 网络模型进行训练; 最后, 将测试集数据输入至训练完成的模型进行估计, 输出 SoH 预测值。


##### 4.1 有效性验证

为验证新型估计方法在 SoH 为[0.88, 0.96]范围内的估计效果, 本节基于 0.2C、0.5C、0.75C 和 1C 倍率的数据, 从测试集和预测区间长度两方面进行验证。首先, 分别选择 0.5C 和 0.75C 倍率的数据作为测试集, 剩余 3 个倍率的数据作为训练集。其次, 针对短充电片段(电压长度设置为 0.2 V)、中等充电片段(电压长度设置为 0.5 V)和长充电片段(电压长度设置为 0.5 V)对所提 SoH 估计方法进行验证。短充电片段选取 3.60~3.80 V, 中等充电片段选取 3.60~4.10 V, 长充电片段选取 3.30~4.10 V。最后, 将不同倍率不同长度电压片段输入至 5 个训练完成的模型, 输出对应的 SoH 估计结果。估计结果如图 9 所示, 估计误差如图 10 所示。

由图 9 和图 10 可知, 不同倍率条件下, 不同片段长度的 SoH 估计误差差异较小, MAE 均在 1.4% 以下, RMSE 和 SDE 均在 1.6% 以下。新型估



(a) 0.5C 倍率下不同区间长度的估计结果



(b) 0.75C倍率下不同区间长度的估计结果

图 9 不同电压区间的估计结果

Fig. 9 Estimation results corresponding to different voltage intervals

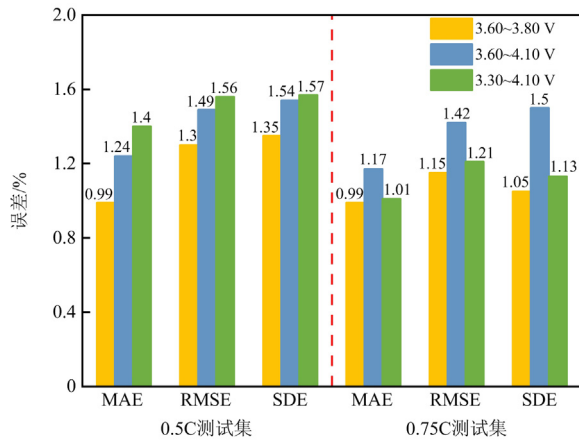


图 10 不同电压区间的误差

Fig. 10 Errors in different voltage intervals

计方法针对不同区间长度均能实现较为理想的估计误差, 且区间长度对所提估计方法无显著影响。

#### 4.2 先进性分析

本节首先将所提方法与其他基于改进 BP 神经网络的方法对比分析, 以表明本文针对 BP 神经网络改进方法的先进性。其次, 将本文所提方法与同类型的基于数据驱动的方法进行对比分析, 以表明本文所提方法的先进性。对比模型和所提模型均选取 0.75C 恒流充电数据作为测试集, 0.2C、0.5C 和 1C 的恒流充电数据作为训练集。模型对比实验中, 为控制“不同模型”这一单一变量, 统一“不同片段长度”的变量, 基于 3 种片段长度, 选取如图 11 所示共 6 个电压片段作为估计模型的输入。6 个电压片段预测结果的平均值作为 SoH 估计值。

##### 4.2.1 和改进 BP 神经网络对比

基于 TI-ECVD 健康特征, 对 GA-BP、LM-BP 和 GA-LM-BP 网络的预测性能进行对比分析。基于

二分法对模型参数进行调试, 以确定最优模型参数。3 种改进 BP 神经网络结构均设置输入层神经元为 2、隐藏层神经元为 5、输出层神经元为 1; GA 算法中, 种群规模为 30, 进化次数为 50, 交叉概率为 0.93, 变异概率为 0.02。不同改进 BP 模型的 SoH 估计结果如图 12 所示。

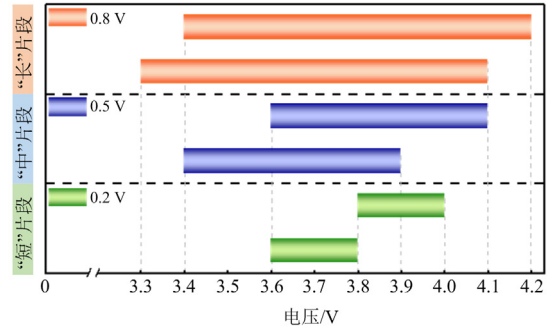

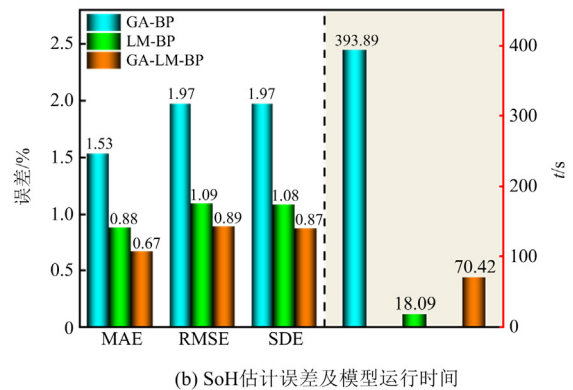


图 11 不同长度的电压片段

Fig. 11 Voltage segments with different lengths



(a) SoH 估计结果



(b) SoH 估计误差及模型运行时间

图 12 不同改进 BP 模型的 SoH 估计

Fig. 12 SoH estimation with different improved BP models

由图 12 可知, 预测点越靠近参考线则预测结果越准确。相比于 GA-BP 模型和 LM-BP 模型, 本文 GA-LM-BP 模型各预测点整体更靠近参考线。具

体而言,本文模型相比于 GA-BP 模型和 LM-BP 模型, MAE 分别下降了 56.2%、23.9%, RMSE 分别下降了 54.8%、18.3%, SDE 分别下降了 55.8%、19.4%。这是由于 GA-BP 模型在权阈值更新机制中仅在误差增大的方向进行搜索最优解,若搜索步长过大易跳过最优解且无法反向搜索,导致陷入局部最优解的概率增加,从而影响估计精度; LM-BP 模型的初始权阈值通过随机选择进行确定,未能克服 BP 神经网络对初始权阈值敏感的问题,很大程度上,初始权阈值的选择限制了后续 BP 神经网络的模型性能,进而影响 SoH 估计精度。

另外,由图 12(b)可知,GA-LM-BP 模型的运行时间较 GA-BP 模型减少了 323.47 s,验证了 LM 算法能有效加快 BP 算法的收敛速度,显著缩短了训练时间。GA-LM-BP 模型的运行时间较 LM-BP 模型增加了 52.33 s。虽然 LM-BP 模型运行时间较短,但其估计精度不及 GA-LM-BP 模型。相比之下,GA-LM-BP 模型在 3 种误差指标下均小于 LM-BP 模型。总体而言,本文方法的运行时间对于模型训练而言并未显著增加时间成本,并且通过引入自动循环训练机制,缩短了重复训练的整体耗时,在保持高精度估计的同时,具备较短的运行时间。

#### 4.2.2 和其他方法对比

本节将本文所提方法与同类型的基于数据驱动的估计方法进行对比分析。选择文献[28]中正弦麻雀搜索算法-支持向量回归(sine sparrow search algorithm-support vector regression, Sine-SSA-SVR)模型和文献[29]中改进灰狼优化算法-长短期记忆网络(improved grey wolf optimizer-long short-term memory, IGWO-LSTM)模型进行对比。由于对比模型的核心任务均为搜寻基础网络中的超参数,仅在搜寻算法与基础网络的选取上存在差异,因此其超参数设置与文献中设计的参数保持一致。各算法的估计结果如图 13 所示。

由图 13 可知,相较于文献[28]的 Sine-SSA-SVR 模型和文献[29]的 IGWO-LSTM 模型,本文所提 GA-LM-BP 模型具有更高的估计精度, MAE 分别下降了 75%、48.9%, RMSE 分别下降了 71.4%、38.2%, SDE 分别下降了 61.5%、40%。这是由于文献[28]中采用 SSA 算法优化 SVR 模型,但 SSA 算法涉及种群规模、迭代次数等多个超参数,仅通过 Sine 函数改进其搜索策略,难以在搜索空间中搜寻 SVR 模型的全局最优超参数;文献[29]中 IGWO 算法对 LSTM 模型的 4 个超参数进行了全面寻优,但在小样本数据输入下, LSTM 模型易产生过拟合现象,导致算法估计精度降低。

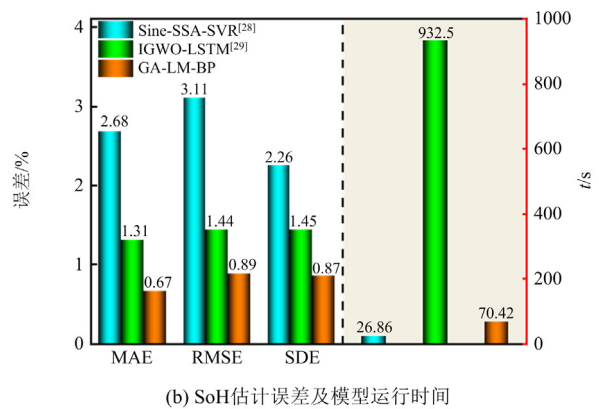
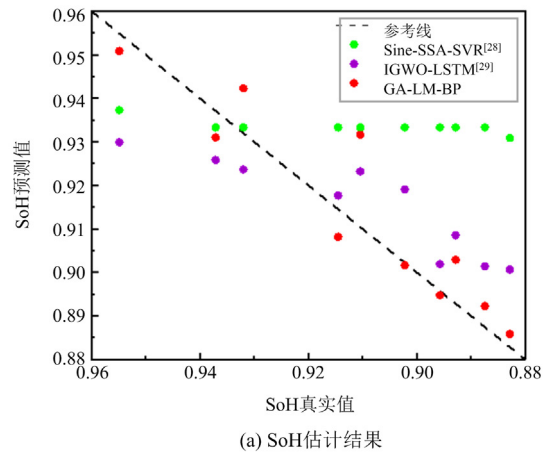


图 13 不同模型的 SoH 估计

Fig. 13 SoH estimation for different models

另外,由图 13(b)模型运行时间可知,与 Sine-SSA-SVR 模型相比,GA-LM-BP 模型的运行时间增加了 43.56 s,但显著提升了估计精度。相较于 IGWO-LSTM 模型,GA-LM-BP 模型的运行时间减少了 862.08 s,降幅高达 92.45%,同时进一步提高了估计精度。以上结果表明了所提基于 GA-LM-BP 网络估计算法的先进性。

## 5 结论

针对锂电池 SoH 估计,提出一种基于新型健康特征及改进 BP 神经网络的 SoH 估计方法。首先,设计 TI-ECVD 作为健康特征,以模拟随机恒流充电片段,简化了 SoH 估计模型的输入参数。其次,基于 BP 神经网络引入 LM 算法,加快了 BP 神经网络的收敛速度,并降低了网络在训练过程中陷入局部最优解的概率。同时,将 GA 算法与 LM-BP 网络融合,降低了因初始权阈值的随机性导致 BP 神经网络陷入局部最优解的可能性。最后,基于自主搭建的实验平台获取实验数据,通过搭建仿真模

型, 与其他改进 BP 神经网络算法及同类型估计方法进行对比分析, 验证了所提估计方法在估计精度和运行速度方面的优势。本文研究内容对于电池储能系统精确的状态估计具有重要意义。未来的研究集中于将温度考虑进模型建立过程, 进一步提高新型估计方法的精度及泛化能力。

## 参考文献

- [1] 吴文进, 郭海婷, 苏建徽, 等. 基于自适应模糊 PID 算法的锂电池组双层均衡控制[J]. 电力系统保护与控制, 2024, 52(2): 111-117.  
WU Wenjin, GUO Haiting, SU Jianhui, et al. Dual-layer equalization control of lithium batteries based on an adaptive fuzzy PID algorithm[J]. Power System Protection and Control, 2024, 52(2): 111-117.
- [2] 邹国发, 高祥, 王春. 考虑锂电池多时间尺度效应的参数辨识与 SOC 估计方法[J]. 电力系统保护与控制, 2024, 52(21): 71-80.  
ZOU Guofa, GAO Xiang, WANG Chun. Parameter identification and SOC estimation methods considering multi-timescale effect lithium batteries[J]. Power System Protection and Control, 2024, 52(21): 71-80.
- [3] 吕炳霖, 刘勇超, 张佳云, 等. 基于充电曲线转换的串联锂离子电池组一致性诊断方法研究[J]. 山东电力技术, 2024, 51(7): 45-51.  
LÜ Binglin, LIU Yongchao, ZHANG Jiayun, et al. A consistency diagnosis method of series-connected lithium-ion batteries based on charging curve transformation[J]. Shandong Electric Power, 2024, 51(7): 45-51.
- [4] LIN Zihui, LI Dagang, ZOU Yuntao. Energy efficiency of lithium-ion batteries: Influential factors and long-term degradation[J]. Journal of Energy Storage, 2023, 74.
- [5] 戴明威, 张春富, 杨佳武. 基于多特征融合的锂电池热失控预警方法[J]. 南方能源建设, 2025, 12(2): 128-133.  
DAI Mingwei, ZHANG Chunfu, YANG Jiawu. Lithium battery thermal runaway warning method based on multi-feature fusion[J]. Southern Energy Construction, 2025, 12(2): 128-133.
- [6] 刘帅邦, 叶佳俊, 李金翰, 等. 锂离子电池生产与服役过程缺陷问题研究综述[J]. 全球能源互联网, 2025, 8(3): 326-335.  
LIU Shuaibang, YE Jiajun, LI Jinhan, et al. Review of defects in the production and service of lithium-ion batteries[J]. Journal of Global Energy Interconnection, 2025, 8(3): 326-335.
- [7] 吴小忠, 肖立华, 童超, 等. 基于传递熵与 JS-BP 神经网络的锂离子电池容量预测模型[J]. 中国电力, 2025, 58(2): 186-192, 215.  
WU Xiaozhong, XIAO Lihua, TONG Chao, et al. Capacity prediction model of lithium-ion batteries based on transfer entropy and JS-BP neural network[J]. Electric Power, 2025, 58(2): 186-192, 215.
- [8] 吴青峰, 杨凯义, 刘立群, 等. 基于一致性算法的锂电池组内单体锂电池 SOH 主动均衡方案[J]. 电力系统保护与控制, 2025, 53(5): 145-155.  
WU Qingfeng, YANG Kaiyi, LIU Liqun, et al. An active SOH balancing scheme based on a consensus algorithm for individual lithium-ion cells in a battery packs[J]. Power System Protection and Control, 2025, 53(5): 145-155.
- [9] 耿萌萌, 范茂松, 魏斌, 等. 基于片段数据的储能电池 SOH 估计[J]. 全球能源互联网, 2025, 8(1): 57-66.  
GENG Mengmeng, FAN Maosong, WEI Bin, et al. SOH estimation of energy storage batteries based on fragmented data[J]. Journal of Global Energy Interconnection, 2025, 8(1): 57-66.
- [10] CHEN Minzhi, MA Guijun, LIU Weibo, et al. An overview of data-driven battery health estimation technology for battery management system[J]. Neurocomputing, 2023, 532: 152-169.
- [11] 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.
- [12] 毛玲, 温佳林, 赵晋斌, 等. 基于集成 ELM 的锂离子电池充电截止电压下的 SOC 和 SOH 联合估计[J]. 电力系统保护与控制, 2023, 51(11): 86-95.  
MAO Ling, WEN Jialin, ZHAO Jinbin, et al. Joint estimation of SOC and SOH at lithium-ion battery charging cut-off voltage based on an ensemble extreme learning machine[J]. Power System Protection and Control, 2023, 51(11): 86-95.
- [13] OJI T, ZHOU Yanglin, CI Song, et al. Data-driven methods for battery soh estimation: survey and a critical analysis[J]. IEEE Access, 2021, 9: 126903-126916.
- [14] REN Jiahui, MA Jinkai, WANG Honghong, et al. A comprehensive review on research methods for lithium-ion battery of state of health estimation and end of life prediction: methods, properties, and prospects[J]. Protection and Control of Modern Power Systems, 2025, 10(3): 146-165.
- [15] 高锋阳, 刘庆寅, 赵丽丽, 等. 改进灰狼优化算法优化 CNN-LSTM 的 PEMFC 性能衰退预测[J]. 电力系统保护与控制, 2025, 53(13): 175-187.

- GAO Fengyang, LIU Qingyin, ZHAO Lili, et al. PEMFC performance degradation prediction based on optimized CNN-LSTM using improved grey wolf optimization algorithm[J]. Power System Protection and Control, 2025, 53(13): 175-187.
- [16] XIONG Rui, YUE Sun, WANG Chenxu, et al. A data-driven method for extracting aging features to accurately predict the battery health[J]. Energy Storage Materials, 2023, 57: 460-470.
- [17] YANG Yalong, CHEN Siyang, CHEN Tao, et al. State of health assessment of lithium-ion batteries based on deep Gaussian process regression considering heterogeneous features[J]. Journal of Energy Storage, 2023, 61.
- [18] PIAO Changhao, SUN Rongli, CHEN Junsheng, et al. A feature extraction approach for state-of-health estimation of lithium-ion battery[J]. Journal of Energy Storage, 2023, 73.
- [19] SUN Shukai, ZHANG Huiming, GE Jiamin, et al. State-of-health estimation for lithium-ion battery using model-based feature optimization and deep extreme learning machine[J]. Journal of Energy Storage, 2023, 72.
- [20] WANG Lihua, YE Wenjing, ZHU Yanjuan, et al. Optimal parameters selection of back propagation algorithm in the feedforward neural network[J]. Engineering Analysis with Boundary Elements, 2023, 151: 575-596.
- [21] WEN Jianping, CHEN Xing, LI Xianghe, et al. SOH prediction of lithium battery based on IC curve feature and BP neural network[J]. Energy, 2022, 261.
- [22] ZHANG Fan, XING Zixuan, WU Minghu. State of health estimation for Li-ion battery using characteristic voltage intervals and genetic algorithm optimized back propagation neural network[J]. Journal of Energy Storage, 2023, 57.
- [23] LI Ning, HE Fuxing, MA Wentao, et al. An indirect state-of-health estimation method based on improved genetic and back propagation for online lithium-ion battery used in electric vehicles[J]. IEEE Transactions on Vehicular Technology, 2022, 71(12): 12682-12690.
- [24] WU Muyao, ZHONG Yiming, WU Ji, et al. State of health estimation of the lithium-ion power battery based on the principal component analysis-particle swarm optimization-back propagation neural network[J]. Energy, 2023, 283.
- [25] XIE Wenlong, GUO Peng, GAO Xinlei. Elucidating the rate limitation of lithium-ion batteries under different charging conditions through polarization analysis[J]. Journal of Energy Storage, 2024, 82.
- [26] WU Jiang, LIU Zelong, ZHANG Yan, et al. Data-driven state of health estimation for lithium-ion battery based on voltage variation curves[J]. Journal of Energy Storage, 2023, 73.
- [27] OSSAI C I, EGWUTUOHA I P. Real-time state-of-health monitoring of lithium-ion battery with anomaly detection, Levenberg-Marquardt algorithm, and multiphase exponential regression model[J]. Neural Computing and Applications, 2021, 33(4): 1193-1206.
- [28] XIA Xuelei, CHEN Yang, SHEN Jiangwei, et al. State of health estimation for lithium-ion batteries based on impedance feature selection and improved support vector regression[J]. Energy, 2025, 326.
- [29] PENG Simin, WANG Yujian, TANG Aihua, et al. State of health estimation joint improved grey wolf optimization algorithm and LSTM using partial discharging health features for lithium-ion batteries[J]. Energy, 2025, 315.

收稿日期: 2025-07-04; 修回日期: 2025-11-27

作者简介:

郭向伟(1987—), 男, 通信作者, 博士, 副教授, 研究方向为电力电子及其在电池管理系统中的应用; E-mail: gxw@hpu.edu.cn

李文静(2001—), 女, 硕士研究生, 研究方向为动力电池状态估计。E-mail: liwenjing0116@163.com

(编辑 魏小丽)