

DOI: 10.19783/j.cnki.pspc.240248

基于 GA-SA-BP 神经网络的锂电池健康状态估算方法

吴青峰¹, 杨艺涛¹, 刘立群¹, 胡秀芳¹, 薄利明², 杨杰豹³

(1. 太原科技大学电子信息工程学院, 山西 太原 030024; 2. 国网山西省电力公司电力科学研究院, 山西 太原 030001; 3. 山西工程技术学院, 山西 阳泉 045000)

摘要: 锂电池健康状态(state of health, SOH)可表征锂电池的老化状况, 准确估算 SOH 对锂电池可靠运行至关重要。为解决模拟退火算法(simulated annealing, SA)和遗传算法(genetic algorithms, GA)优化的 BP 神经网络收敛效率低、易陷入局部最优无法到达全局最优解的问题, 提出一种 GA-SA-BP 神经网络算法来提高 SOH 估算精度。首先, 分析 NASA 公开数据集数据各个健康因子(health indicator, HI)与 SOH 相关性, 选取与 SOH 相关性更高的锂电池输出电压、输出电流、容量和等压降放电时间 4 个 HI 作为 BP 神经网络的输入值, 以提高 SOH 估算精度。其次, 提出 GA-SA-BP 神经网络算法来估算 SOH, 通过在陷入局部最优时跳出局部最优找到全局最优解, 以便进一步提高 SOH 估算精度。最后, NASA 锂电池数据集和锂电池实验测试平台取得的结果表明, 与传统 BP 神经网络、GA-BP 神经网络和 SA-BP 神经网络相比, 所提方案提高了 SOH 估算精度, 在部分数据缺失的情况下仍具有有效性。

关键词: 锂电池; 健康状态估算; 神经网络; 健康因子

Lithium battery state of health estimation method based on a GA-SA-BP neural network

WU Qingfeng¹, YANG Yitao¹, LIU Liqun¹, HU Xiufang¹, BO Liming², YANG Jiebao³

(1. College of Electronic Information Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China; 2. State Grid Shanxi Electric Power Research Institute, Taiyuan 030001, China; 3. Shanxi Institute of Engineering and Technology, Yangquan 045000, China)

Abstract: The state of health (SOH) of lithium batteries can characterize their aging status, and accurately estimating SOH is crucial for reliable operation. A GA-SA-BP neural network algorithm is proposed to improve the accuracy of SOH estimation to solve the problem of low convergence efficiency and susceptibility to local optima of BP neural networks optimized by simulated annealing (SA) and genetic algorithms (GA), which cannot reach the global optimum. First, the correlation between various health indicators (HI) and SOH in NASA's publicly available dataset is analyzed, and the four HI values of lithium battery output voltage, output current, capacity, and equal voltage drop discharge time with higher correlation with SOH is selected as input values for the BP neural network to improve the accuracy of SOH estimation. Secondly, the GA-SA-BP neural network algorithm is proposed to estimate SOH, and the global optimal solution is found by jumping out of the local optimum when trapped in order to further improve the accuracy of SOH estimation. Finally, the results obtained on the NASA lithium battery dataset and lithium battery experimental testing platform indicate that the proposed approach improves the accuracy of SOH estimation compared to traditional BP neural networks, GA-BP neural networks, and SA-BP neural networks, and remains effective even in the absence of some data.

This work is supported by the National Key R&D Program of China (No. 2018YFA0707305).

Key words: lithium battery; estimate of state of health; neural network; health indicator

0 引言

随着“双碳”目标的提出, 微电网系统和电动

汽车得到快速发展。锂电池具有能量密度高、无记忆性以及自放电率低的优点, 被广泛应用于电动汽车、微电网等场景^[1-4]。锂电池健康状态(state of health, SOH)指标表征锂电池的老化状态^[5-6]。通过观察 SOH 值可以判断锂电池的运行状态, 当锂电池 SOH 降到规定值时, 锂电池管理系统会作出预警, 方便工作人员对老化锂电池进行更换, 在保证整个系统的稳定运行的同时降低了锂电池运行的维护成本^[7]。

基金项目: 国家重点研发计划项目资助(2018YFA0707305); 山西省基础研究计划面上项目资助(202203021221153); 阳泉市应用基础研究计划项目资助(2022JH059); 山西省研究生教育创新项目资助(2024KY659)

目前对 SOH 的估算方法可以分为 3 类: 直接测量法、模型化方法以及数据驱动法^[8]。直接测量法需要对锂电池进行多次完整的充放电实验, 对测量技术要求很高, 只能对锂电池 SOH 进行离线估算^[9]。基于模型的锂电池 SOH 估算算法需要较大计算量, 计算精度低^[10]。基于数据驱动的方法不受锂电池型号和工作状态限制, 在锂电池的老化试验中提取出输入数据估算 SOH, 可行性和实用性更强^[11]。因此, 本文重点研究基于数据驱动的 SOH 估算算法。

在锂电池 SOH 估算过程中可以利用锂电池的健康因子(health indicator, HI)表征锂电池 SOH, HI 的提取关系到 SOH 的估算准确度^[12]。文献[13-14]分别将容量增量曲线和恒电流放电时间作为 HI, 从而实现 SOH 的估算。但文献[13-14]提取的 HI 信息过少, 不足以提取完整的特征信息。文献[15-16]分别从电压、电流和温度等变量曲线中提取几类 HI 进行 SOH 估计, 提取 HI 数量过多且提取过程较复杂。过多的 HI 会增加对计算机计算能力和数据存储能力的要求, 降低 SOH 的估算速度。

提取 HI 后, 需要利用数据驱动的方法对 HI 进行训练, 从而得到 SOH。在各种基于数据驱动的 SOH 估算方法中, 基于 BP 神经网络的 SOH 估算算法具有高度自学习和自适应能力, 得到学者的广泛关注。但传统 BP 神经网络采取最速下降法对 SOH 进行估算, 会产生收敛速度慢以及只能到达局部最优解而无法寻找全局最优等问题^[17]。针对此问题, 文献[18]提出了一种由遗传算法(genetic algorithms, GA)优化的 BP 神经网络, 提高了 SOH 的估算精度。文献[19-20]分别对 GA-BP 算法进一步优化, 提高了搜索能力和收敛速度, 但仍未摆脱基于 GA-BP 神经网络的 SOH 估算面临着易陷入局部最优而无法到达全局最优解的问题。文献[21]引入了模拟退火算法(simulated annealing, SA)解决了传统 BP 神经网络易陷入局部最优解的问题, 优化了 BP 神经网络的权值, 但阈值没有优化, 存在全局搜索能力差、容易受参数影响的问题。

综上所述, 现有基于 SA-BP 和 GA-BP 神经网络的 SOH 估算算法存在无法进行全局寻优以及固定遗传变异概率造成的迭代效率较低等问题。基于此, 本文提出了基于 GA-SA-BP 的神经网络来估算 SOH 值。选取与 SOH 相关性更高的参数作为 HI, 通过在陷入局部最优时跳出局部最优, 从而找到全局最优解, 该方法提高了锂电池 SOH 的估算精度。

1 SOH 的 HI 提取

锂电池 SOH 表征锂电池的老化状态, 本文利用基于容量的 SOH 计算公式来获取锂电池 SOH 值, 其表达式如式(1)^[22]所示。

$$\alpha_{\text{SOH}} = \frac{C_{\text{aged}}}{C_{\text{new}}} \times 100\% \quad (1)$$

式中: α_{SOH} 为锂电池 SOH 值; C_{aged} 为锂电池循环结束后的最大容量; C_{new} 为循环前的最大容量。

为选取合适的 β_{HI} 值, 分析了各 HI 和锂电池容量之间的相关度。各项 HI 与 SOH 的相关度可以用皮尔逊积矩相关系数(pearson product-moment correlation coefficient, PPMCC)来表示^[23]。PPMCC 的表达式如式(2)所示。通常情况下, 当皮尔逊积矩相关系数 r 值越高时, 相关性就越强。

$$r = \frac{\sum_{n=1}^N (\beta_{\text{HI},n} - \overline{\beta_{\text{HI}}})(C_{\text{aged},n} - \overline{C_{\text{aged}}})}{\sqrt{\sum_{n=1}^N (\beta_{\text{HI},n} - \overline{\beta_{\text{HI}}})^2} \sqrt{\sum_{n=1}^N (C_{\text{aged},n} - \overline{C_{\text{aged}}})^2}} \quad (2)$$

式中: N 为锂电池的循环次数; $\beta_{\text{HI},n}$ 为锂电池第 n 次循环的 HI 值; $\overline{\beta_{\text{HI}}}$ 为 HI 的平均值; $C_{\text{aged},n}$ 为锂电池第 n 次循环后的容量; $\overline{C_{\text{aged}}}$ 为锂电池的平均容量。

利用皮尔逊积矩相关系数计算锂电池输出电流、输出电压、输入电流、输入电压以及等压放电时间 5 个 HI 的 r 值。由图 1 可以看出, 锂电池容量、输出电流、输出电压以及等压放电时间与 SOH

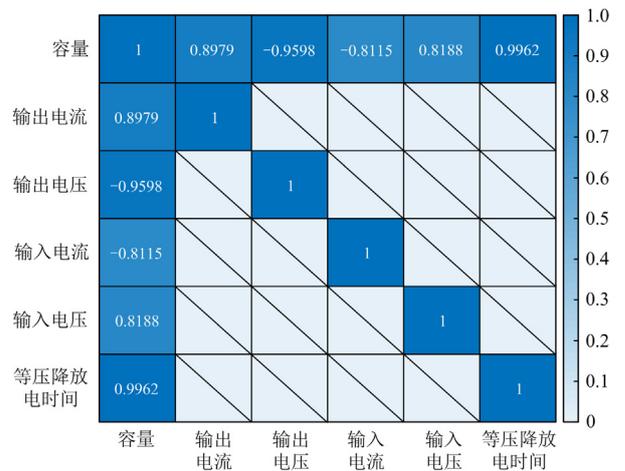


图 1 各项 HI 的健康指数色温图

Fig. 1 Colour temperature diagram of the health index for each HI

的相关性相对更高,所以本文选这4个HI作为BP神经网络的输入量。

本文运用NASA^[24]数据库中的锂电池老化数据对SOH进行估算。图2分别为NASA数据库中5号、6号、7号锂电池的老化数据。该组数据对LG Chem 18650锂电池进行了多次充放电测试,其中18650锂电池额定容量为3200mAh、额定电压为3.6V、充电电流为1625mA。首先以1.5A的恒定电流给锂电池充电直到电压为4.2V,然后以恒压模式充电到充电电流下降至20mA,随后以2A的恒定电流对锂电池放电直到达到最小截止电压。

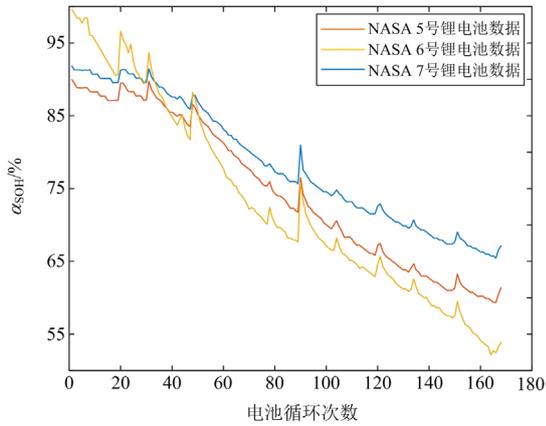


图2 NASA数据库锂电池SOH变化曲线

Fig. 2 SOH variation curve of lithium batteries in NASA database

2 基于GA-SA-BP神经网络的SOH估算模型构建

2.1 基于GA优化算法的BP神经网络

针对传统BP神经网络的缺点,有学者提出GA-BP神经网络^[25-26]。GA-BP神经网络是模拟自然界生物“物竞天择,适者生存”的机理形成的寻优方法。该方法对种群中的个体进行不断的选择、交叉、变异,按照适应度函数将适应度值较差的个体淘汰,保留适应度较好的个体,使得留下的群体不断地更新产生新一代,直到满足约束条件。通过这个过程克服了传统BP神经网络的缺点,提高了估算精度。GA-BP神经网络的步骤如下。

第1步:将变量转换为染色体,选择合适的编码方案。选择合适的种群大小以及 k_1 、 k_2 、 k_3 、 k_4 ,确定适应度函数,并随机产生一个初始种群(含有 M 个个体)。

第2步:选择。利用式(3)计算出每一串的累计概率 q_i 及选择概率 P_i 。通过适应度比例方法计算出适应度,将适应度大的个体放回种群。

$$\begin{cases} F = \sum_{i=1}^M f_i \\ P_i = \frac{f_i}{F} \\ q_i = \sum_{j=1}^i P_j \end{cases} \quad (3)$$

式中: f_i 为每一串染色体的适应度; F 为总适应度; P_i 为每一串染色体的选择概率; q_i 为累计概率; M 为种群中的个体的数量。

第3步:交叉。从种群中选择两个个体,随机选择一个或者多个染色体位置进行交换组合来产生一个更优秀的个体。

第4步:变异。从种群中任选一个个体进行变异产生一个更优秀的个体。

GA-BP神经网络流程图如图3^[27]所示。由于GA优化算法使用固定的遗传变异参数,对不同适应度的个体进行同样的遗传操作,精确性较差,不能很好地解决计算量过大的问题,会出现“早熟”现象,因此,需要对传统的GA-BP神经网络进行改进^[28]。

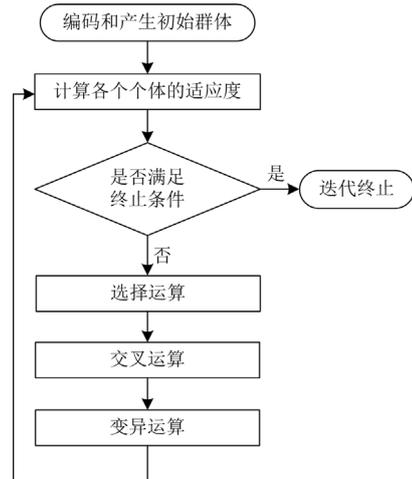


图3 GA优化算法流程图

Fig. 3 GA optimization algorithm flow chart

2.2 基于SA优化的BP神经网络

针对GA-BP神经网络的缺点,有学者提出SA-BP神经网络。SA-BP神经网络模仿了固体物体的退火状态:升温时,固体内能增大且内部粒子逐渐无序,冷却时如果降温的过程足够缓慢,固体内部粒子始终处于平衡状态,当降到某一个低温时达到最小内能;而如果降温过于迅速则降到同一低温时内能恒定不变。SA优化算法的运行规律是给定模型一个较高的初始温度,随着温度的不断下降,当算法与概率突变特性相结合时,在解空间中跳出局部最优解,寻找到最优解。SA优化算法包括内

循环和外循环两部分, 内循环运用 Metropolis 算法在每个温度保持不变的情况下分别迭代 L 次, 找出此温度下的最小能量值作为最优解。当后一个状态的能量比前一个状态的能量低时, 接受后一个状态的能量。外循环是退火过程, 由初始温度按照降温系数 α 开始降温, 最终达到终止温度, 此时外循环的退火过程结束。

SA-BP 神经网络的步骤如图 4^[29]所示。SA-BP 神经网络针对传统 GA-BP 神经网络容易陷入局部最优解的问题, 通过内循环和外循环运用 Metropolis 准则, 有概率地跳出算法的局部最优解, 达到全局最优解。但 SA-BP 神经网络存在全局搜索能力差, 容易受参数影响的问题^[30]。

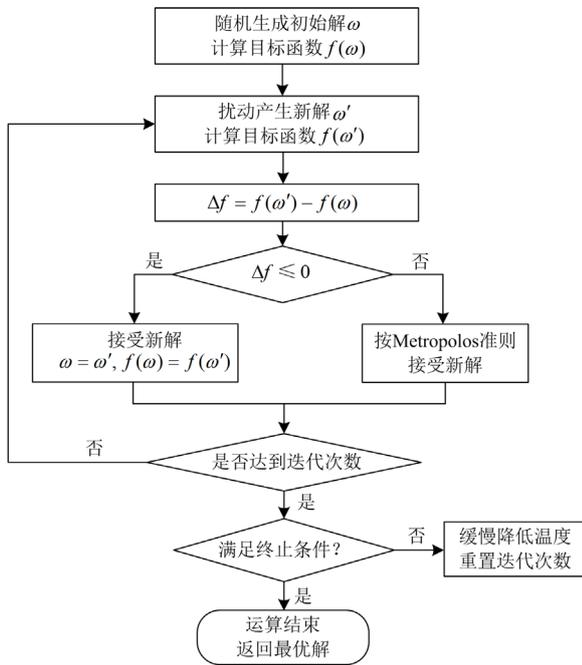


图 4 SA-BP 神经网络步骤图

Fig. 4 SA-BP neural network step diagram

2.3 基于 GA-SA 优化的 BP 神经网络

针对传统 BP、GA-BP 和 SA-BP 神经网络存在的问题, 提出一种基于 GA-SA 联合优化的 BP 神经网络, 从而实现对 SOH 的高精度估算。首先, 采用自适应 GA-BP 神经网络克服传统 GA-BP 神经网络交叉概率 P_c 和遗传概率 P_m 固定不变、效率低下的缺点。其次, 将 SA 算法引入 GA-BP 神经网络循环, 形成 GA-SA-BP 神经网络。该方案克服了传统 GA-BP 神经网络在初始值选取不当时, 出现的局部收敛、无法找到全局最优解的局限性。同时, 也解决了传统 SA-BP 神经网络全局搜索能力差、受参数影响大的问题。在保留传统 GA-BP 神经网络和 SA-BP 神经网络优点的同时克服了两者的问题。

GA-SA-BP 神经网络的流程框图如图 5 所示。

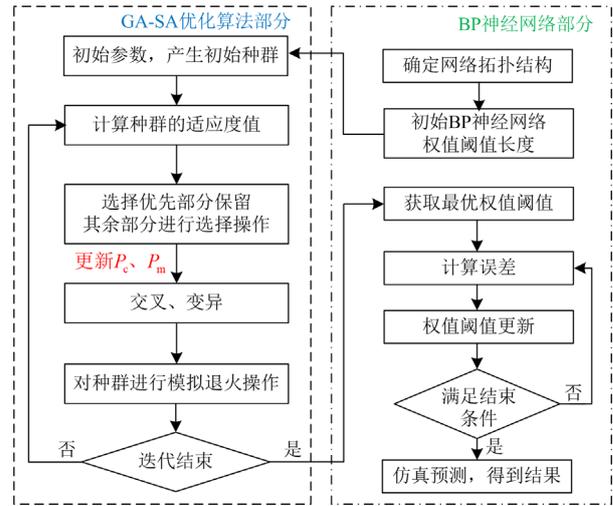


图 5 GA-SA-BP 神经网络

Fig. 5 GA-SA-BP neural network

基于 GA-SA-BP 神经网络的具体流程如下。

第 1 步: 提取训练数据表的输入值。分析 NASA 公开数据集的恒流、恒压充放电操作, 提取出锂电池容量、输出电流、输出电压以及等压放电时间作为 HI, 选取 60 组数据作为 BP 神经网络的训练集输入值。

第 2 步: 利用自适应 GA 算法优化神经网络。传统 GA-BP 神经网络中 GA 算法的交叉、变异值 (P_c 和 P_m) 为固定值, 无论适应度高都经过了相同概率的交叉和变异操作, 影响了算法的效率。因此, 采用自适应 GA-BP 神经网络在估算 SOH 时不断更新遗传变异的概率, 使得迭代效率更高。自适应 GA-BP 神经网络中 P_c 和 P_m 的计算公式分别为

$$P_c = \begin{cases} k_1 \frac{f_{\max} - f'}{f_{\max} - f_{\text{avg}}}, & f' \geq f_{\text{avg}} \\ k_3, & f' < f_{\text{avg}} \end{cases} \quad (4)$$

$$P_m = \begin{cases} k_2 \frac{f_{\max} - f'}{f_{\max} - f_{\text{avg}}}, & f' \geq f_{\text{avg}} \\ k_4, & f' < f_{\text{avg}} \end{cases} \quad (5)$$

式中: P_c 为交叉概率; P_m 为交叉概率; f_{\max} 为群体的最大适应度; f_{avg} 为群体的平均适应度; f' 为选择两个交叉个体中适应度较高个体的适应度值; k_1 、 k_2 、 k_3 、 k_4 为常数。

第 3 步: 利用 SA 优化算法求最优解。求最优解示意图见图 6。A 为给定的较高温, 若继续采用第 2 步中传统 GA-BP 神经网络的梯度下降方法会停止迭代, 只能到达局部最优解 B 或 C 而无法达到

全局最优解 D 。此时，引入 SA 优化算法后， B 点之后能量进一步上升，按照一定的概率 P 跳出局部最优解，直到寻到全局最优解 D 。当下一时刻能量低于此时能量时，跳出循环的概率为 1，当下一时刻能量高于此时能量时，按照式(6)所算出的概率跳出循环。

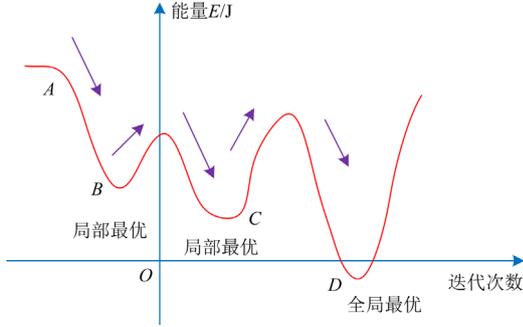


图 6 SA 算法求最优解示意图

Fig. 6 Schematic diagram of SA algorithm seeking optimal solution

$$P = \begin{cases} 1, & E(n+1) < E(n) \\ e^{-\frac{E(n+1)-E(n)}{T}}, & E(n+1) \geq E(n) \end{cases} \quad (6)$$

式中： $E(n)$ 表示当前时刻的能量； $E(n+1)$ 表示下一时刻的能量； P 表示由 $x(n)$ 到 $x(n+1)$ 的接受概率； T 为温度常数。

第 4 步：对锂电池 SOH 进行估算。将训练集代入训练后的神经网络，以锂电池容量、输出电流、输入电流以及等压降放电时间 4 个 HI 作为输入，SOH 值作为输出，通过对比与实际值的误差大小来评价 GA-SA-BP 神经网络的有效性。

3 所提方案 SOH 估算结果分析

本实验基于 CPU(Intel Core i7-9850H 2.6 GHz)、GPU(NVIDIA GeForce GTX1070Ti)、RAM 内存 (32 GB)、Windows10 操作系统等软硬件。选取 NASA 数据库中单个 18650 锂电池充放电过程中的电压电流等数据作为训练样本。将数据集分为训练集和测试集两部分，训练集负责训练 BP 神经网络、测试集用于测试训练完毕的 GA-SA-BP 神经网络的效果。使用参数辨识的方法提取出 PPMCC 值更高的锂电池容量、输出电流、输出电压以及等压降放电时间，作为 BP 神经网络的输入值，输出值为 SOH，构建 4 个输入值，一个输出值的 BP 神经网络。首先设置 GA-SA-BP 神经网络里的各项参数，其次产生初始种群对其进行选择、遗传、交叉、变异等操作。随后在陷入局部最优解时，使用退火操作跳出局部最优解，从而实现全局最优解。锂电池 SOH 估算算法流程图如图 7 所示。

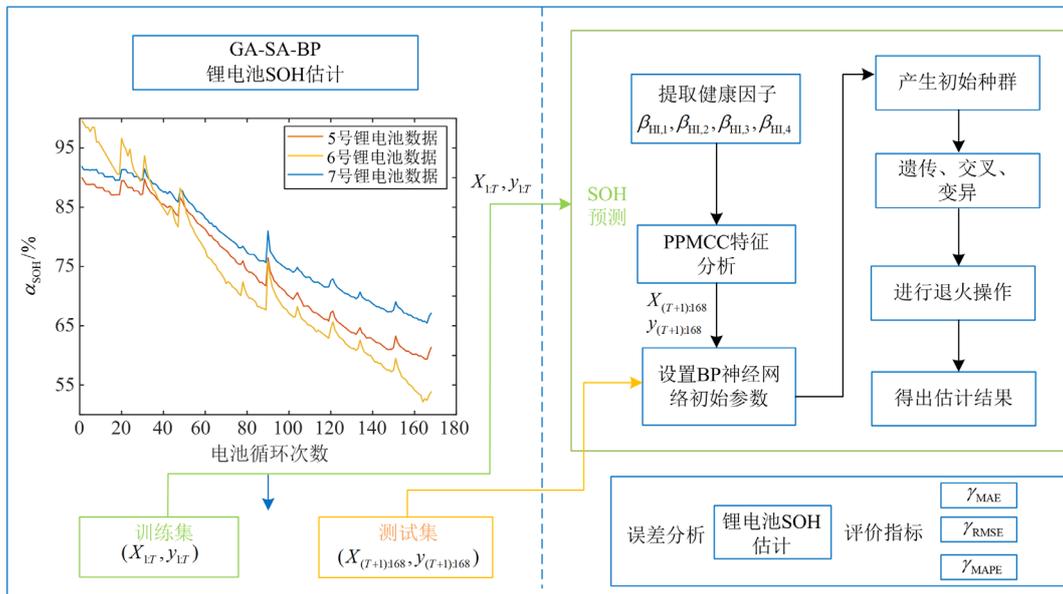


图 7 锂电池 SOH 估算算法流程图

Fig. 7 Flow chart of the SOH estimation algorithm for lithium batteries

为验证所提方案的有效性，分别选用平均绝对误差(mean absolute error, MAE) γ_{MAE} 、均方根误差

(root mean square error, RMSE) γ_{RMSE} 以及平均绝对百分比误差(mean absolute percentage error, MAPE)

γ_{MAPE} 作为误差评定标准。这 3 个指标的表达式^[31] 分别为

$$\gamma_{\text{MAE}} = \frac{1}{L} \sum_{k=1}^L |\alpha_{\text{SOH,estimation}}^k - \alpha_{\text{SOH,true}}^k| \quad (7)$$

$$\gamma_{\text{RMSE}} = \sqrt{\frac{\sum_{k=1}^L (\alpha_{\text{SOH,estimation}}^k - \alpha_{\text{SOH,true}}^k)^2}{L}} \quad (8)$$

$$\gamma_{\text{MAPE}} = \frac{1}{L} \sum_{k=1}^L \left| \frac{\alpha_{\text{SOH,estimation}}^k - \alpha_{\text{SOH,true}}^k}{\alpha_{\text{SOH,estimation}}^k} \right| \quad (9)$$

式中: $\alpha_{\text{SOH,estimation}}^k$ 为锂电池 SOH 估计值; $\alpha_{\text{SOH,true}}^k$ 为锂电池 SOH 真实值; L 为样本个数。

本文根据 GA-SA、SA 以及 GA 算法的适应度曲线对比各算法的适应度。从图 8 可以看出, 本文所提 GA-SA-BP 算法的适应度比 GA-BP 和 SA-BP 的适应度分别提前 4 次和 7 次收敛到最小值, 迭代效率分别提高了 57% 和 70%。

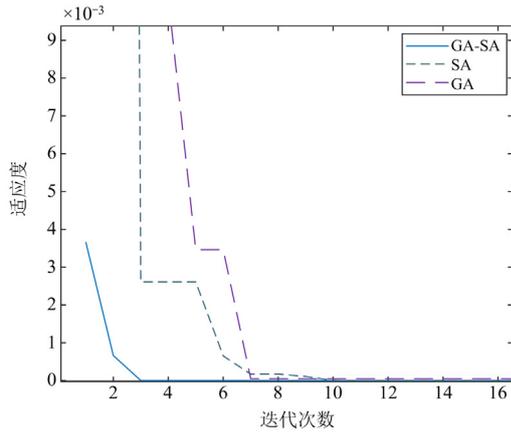


图 8 3 种算法适应度曲线对比图

Fig. 8 Comparison chart of fitness curves for three algorithms

1) 工况 1: 不同 HI 对 SOH 估算的影响分析

采用本文所提 HI 提取方案及 GA-SA-BP 神经网络对 SOH 进行估算, 得到的误差图如图 9 所示。 α_{SOH} 估算值与实际值误差仅为 0.203%。采用文献[13]所提的容量增量曲线和恒定电流放电时间作为 HI 实现 SOH 估算, 得到的 α_{SOH} 估算值与实际值误差为 0.606%。采用文献[15]从电压、电流和温度等变量曲线中提取几类 HI 进行 SOH 估计, 得到的 α_{SOH} 估算值与实际值误差为 0.424%。通过分析图 9 可知, 文献[13]提取的 HI 信息过少, 无法获得完整的 SOH 估计信息从而得到精确的 SOH 估计值。文献[15]的 HI 提取过程较复杂, 提取 HI 数量过多, 且 SOH 估算精度不及本文所提方案。本文在使用较

少训练数据的前提下提高了 SOH 估算精度, 降低了对硬件计算能力的要求。

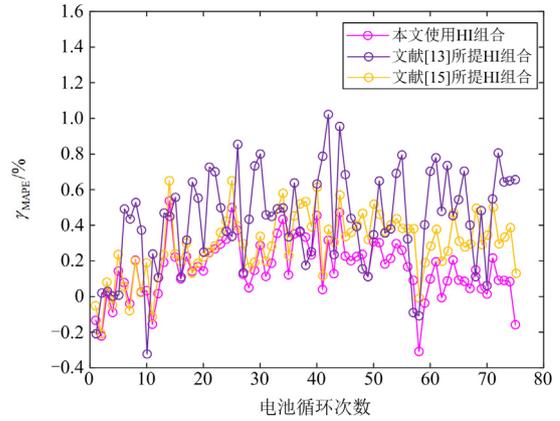


图 9 所提 HI 方案与现有文献对比验证

Fig. 9 Validation of the proposed HI scheme in comparison with existing literature

2) 工况 2: 所提算法与现有算法对比分析

图 10 为 5 号锂电池分别采用传统 BP 神经网络、GA-BP 神经网络、SA-BP 神经网络以及本文所提基于 GA-SA-BP 神经网络得到的 α_{SOH} 值。选取的训练样本数为 60, 测试样本数为 75, 初始种群为 100。根据图 10 分析可知, 与传统 BP 神经网络、GA-BP 神经网络、SA-BP 神经网络相比, 本文所采用的 GA-SA-BP 神经网络优化后的 α_{SOH} 估算值更接近真实值, 验证了本文所提算法的优越性和适应性。图 11 为 4 种神经网络的 γ_{MAPE} 对比图。由图 11 可以看出, 使用 GA-SA-BP 神经网络估算 SOH 的 γ_{MAPE} 值最小, 曲线更靠近 0, 说明本文所提算法相比 BP 神经网络、GA-BP 神经网络和 SA-BP 神经网络有较大改进, 提高了 SOH 的估算精度。

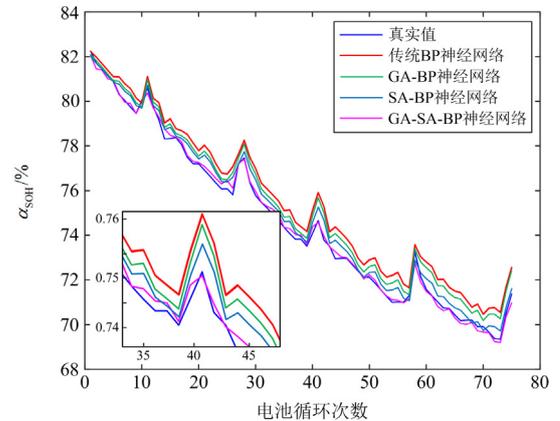


图 10 5 号锂电池 SOH 估算值与真实值对比图

Fig. 10 Comparison of SOH predicted value and true value for lithium battery No. 5

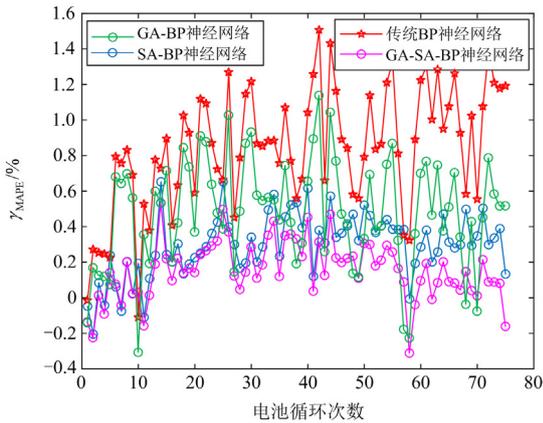


图 11 5 号锂电池 4 种算法测试集误差对比曲线

Fig. 11 Comparison curve of the error of four algorithms' test sets for lithium battery No. 5

表 1 列出了 5 号锂电池 NASA 数据集采用上述 4 种算法得到 SOH 的 γ_{MAE} 、 γ_{RMSE} 和 γ_{MAPE} 数据。误差值越小说明 α_{SOH} 值估算越准确。由表 1 可以看出, 相比传统 BP 神经网络、GA-BP 神经网络、SA-BP 神经网络, 本文提出的 GA-SA-BP 神经网络对 SOH 的预测更精确、误差更小。

表 1 4 种算法误差对比表(5 号锂电池)

Table 1 Comparison table of the errors of the four algorithms (lithium battery No. 5)

算法	γ_{MAE}	γ_{RMSE}	γ_{MAPE}
BP	0.008 47	0.009 11	1.149
GA-BP	0.006 02	0.006 70	0.816
SA-BP	0.003 91	0.004 16	0.483
GA-SA-BP	0.001 52	0.001 92	0.203

3) 工况 3: 所提算法在不同数据集适应性分析

为了进一步验证所提方案的普适性, 将所提方案运用于 7 号锂电池 NASA 数据集, 并将所提方案和传统 BP 神经网络、GA-BP 神经网络、SA-BP 神经网络进行对比, 得到的数据如图 12 和图 13 所示。与 5 号锂电池测试结果类似, 所提 GA-SA-BP 神经网络仍能提高 NASA 数据集 7 号锂电池的 SOH 估算精度, 表明所提方案具有很好的普适性。表 2 为 4 种神经网络误差数据对比表。和其他 3 种神经网络方案相比, 表 2 数据表明所提方案 SOH 估算误差最小。

4) 工况 4: 所提算法在采样数据缺失情况下的有效性分析

在采集数据的过程中可能会存在部分数据组缺失的情况^[32]。为进一步验证所提方案在数据存在缺失时的有效性, 假设 5 号锂电池 NASA 数据集丢失

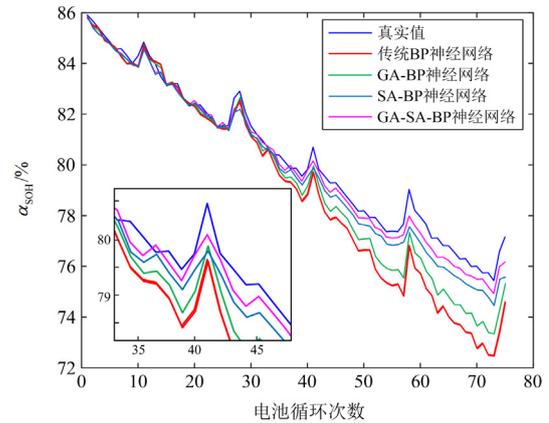


图 12 7 号锂电池 SOH 估算值与真实值对比图

Fig. 12 Comparison of SOH predicted value and true value for lithium battery No. 7

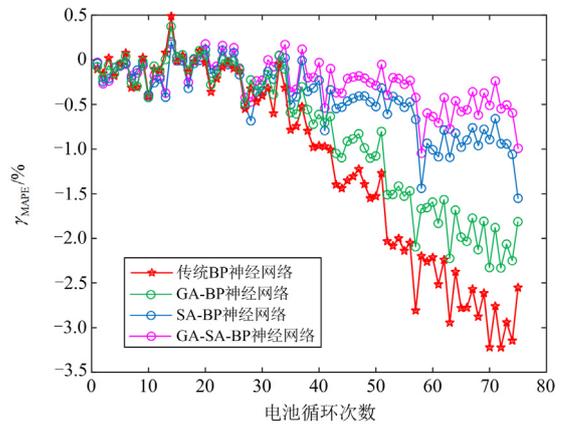


图 13 7 号锂电池 4 种算法测试集误差对比曲线

Fig. 13 Comparison curve of the error of four algorithms' test sets for li-ion battery No. 7

表 2 4 种算法误差对比表(7 号锂电池)

Table 2 Comparison table of the errors of the four algorithms (lithium battery No. 7)

算法	γ_{MAE}	γ_{RMSE}	γ_{MAPE}
BP	0.011 62	0.000 02	1.493
GA-BP	0.008 34	0.011 29	1.072
SA-BP	0.004 51	0.005 77	0.575
GA-SA-BP	0.002 87	0.003 64	0.363

了部分数据, 将所提方案和传统 BP 神经网络进行对比, 得到对比结果如图 14 和图 15 所示。由于丢失了部分数据, 图 14 中的 SOH 波形和图 10 未丢失数据的 SOH 波形略有不同。与工况 2 得到的测试结果类似, GA-SA-BP 神经网络在数据缺失的情况下也能精准地估计锂电池 SOH。

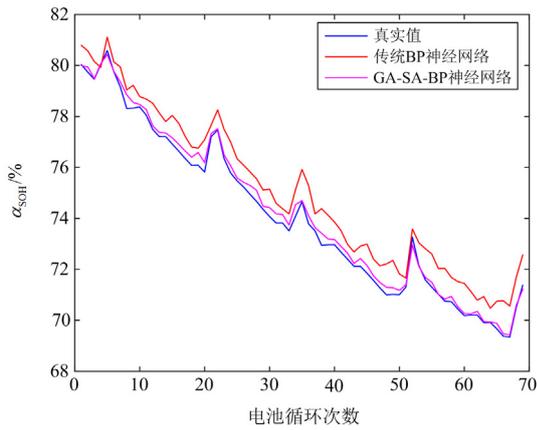


图 14 锂电池数据缺失时 SOH 估算值与真实值对比图
Fig. 14 Comparison chart of SOH predicted value and actual value when lithium battery data is missing

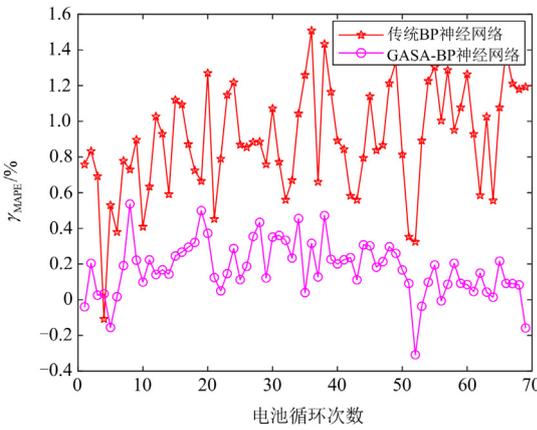


图 15 锂电池数据缺失时算法测试集误差对比曲线
Fig. 15 Comparison curve of algorithm test set error when lithium battery data is missing

4 所提方案的实验结果分析

为进一步验证本文所提方案的实际应用价值, 利用锂电池实验平台进行锂电池充放电测试, 并进行 SOH 估算。图 16 为锂电池充放电循环及测试系统, 包括锂电池循环系统、保温箱以及上位机。实验中分别将额定电压为 3 V 的 CR2032 锂电池进行恒流充放电测试, 分别记录 400 次循环时的电压、电流以及容量等参数, 利用本文所提方案对实验数据进行训练, 通过对比测试得到 α_{SOH} 值与 α_{SOH} 真实值的误差, 进一步验证所提方案的有效性和普适性。

图 17 为 CR2032 锂电池分别运用传统 BP 神经网络、GA-BP 神经网络、SA-BP 神经网络以及本文所提基于 GA-SA-BP 神经网络得到的 α_{SOH} 值。与图 10 使用 NASA 数据集得到的 α_{SOH} 分析结果类似, 相比其他 3 种神经网络, 本文所提 GA-SA-BP 神经

网络得到的 α_{SOH} 估算值更接近真实值, 验证了本文所提算法的优越性。图 18 为采用上述 4 种神经网络 SOH 估算算法得到的 γ_{MAPE} 对比结果。从图 18 可以



图 16 锂电池充放电循环测试系统
Fig. 16 Lithium battery charging and discharging cycle testing system

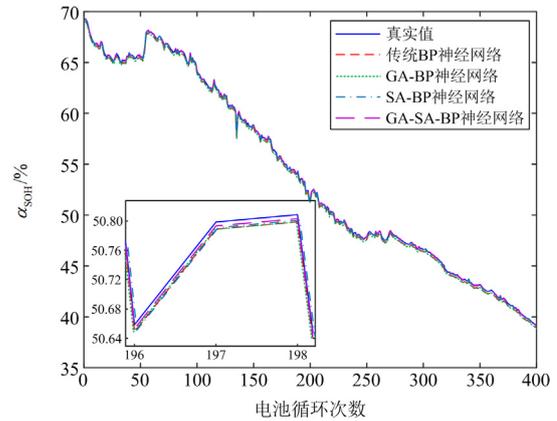


图 17 锂电池 SOH 估算值与真实值对比图
Fig. 17 Comparison chart between SOH predicted value and actual value of lithium battery

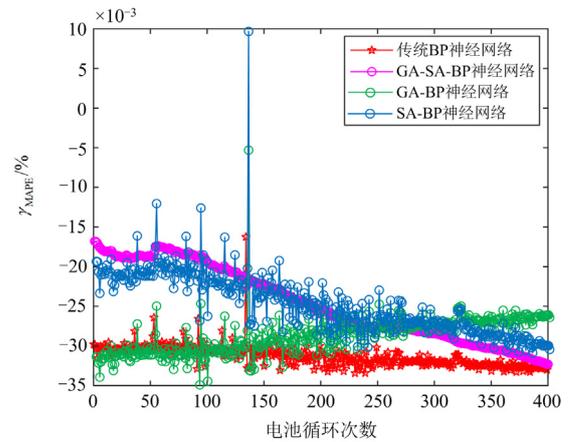


图 18 锂电池 4 种算法测试集误差对比曲线
Fig. 18 Comparison curves of test set errors of four algorithms for lithium batteries

看出,这4种神经网络算法中,使用所提 GA-SA-BP 神经网络的 γ_{MAPE} 最小,说明相比上述4种方法本文所提算法在经过长时间循环后估算精度更高。

表3列出了BP神经网络、GA-BP神经网络、SA-BP神经网络和GA-SA-BP神经网络得到的SOH的 γ_{MAE} 、 γ_{RMSE} 和 γ_{MAPE} 数据。由表3可以看出,这4种神经网络算法中,本文提出的GA-SA-BP神经网络的SOH估算误差最小,验证了在经过多次充放电循环实验后本文所提方法对SOH估算仍有较高精度。

表3 4种算法误差对比表(CR2032)

Table 3 Comparison table of the errors of the four algorithms (CR2032)

算法	γ_{MAE}	γ_{RMSE}	γ_{MAPE}
BP	0.141 13	0.156 08	0.032
GA-BP	0.121 73	0.139 82	0.027
SA-BP	0.119 97	0.123 14	0.025
GA-SA-BP	0.1008 51	0.103 38	0.019

5 结论

本文对锂电池各项HI与SOH之间的关系进行了分析,研究了传统BP神经网络、SA-BP神经网络和GA-BP神经网络估算SOH的原理及目前存在的问题。在此基础上,提出了一种基于GA-SA-BP神经网络的锂电池SOH估算算法,本文的结论如下。

1) 根据NASA数据集利用PPMCC获取各项HI与SOH相关度,提取出与SOH相关度更高的4个HI作为GA-SA-BP神经网络的输入项,相关性更强且易于获取,更便于间接量化锂电池的老化过程,在减少训练数据的同时提高了锂电池SOH的估算精度。

2) 提出GA-SA-BP神经网络来优化参数,提高SOH估算的精度。解决了传统BP神经网络存在的问题,采用自适应GA算法不断改变迭代过程中交叉和变异的数值,提高了迭代效率。并引入SA算法跳出局部最优解,寻找全局最优解,进一步提高了锂电池SOH的估算精度。

3) 基于NASA锂电池数据集以及实验平台上验证结果说明,将本文所提HI作为神经网络的输入值进行训练,可提高SOH估算精度。同时与现有BP神经网络、SA-BP神经网络和GA-BP神经网络进行对比,实验数据表明,与传统方案相比所提方案的误差大大降低,仅为0.203%,并适用于不同NASA锂电池数据集和数据缺失的情况。

参考文献

- [1] 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.
- [2] 薄利明, 郑惠萍, 张世锋, 等. 锂电池健康状态均衡技术综述[J]. 电测与仪表, 2023, 60(4): 11-18.
BO Liming, ZHENG Huiping, ZHANG Shifeng, et al. Review on health state equalization technology for lithium batteries[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 11-18.
- [3] 尚彦赟, 宋红为, 杨照光, 等. 基于二阶RC模型的锂电池充放电特性分析[J]. 高压电器, 2023, 59(7): 87-94.
SHANG Yanyun, SONG Hongwei, YANG Zhaoguang, et al. Charge and discharge characteristics analysis of lithium battery based on second-order RC model[J]. High Voltage Apparatus, 2023, 59(7): 87-94.
- [4] 孔文俊, 张艳森, 汤效平, 等. 大容量储能锂电池电芯产热特性研究[J]. 发电技术, 2022, 43(5): 801-809.
KONG Wenjun, ZHANG Yansen, TANG Xiaoping, et al. Study on heat production characteristics of lithium-ion batteries for large capacity energy storage[J]. Power Generation Technology, 2022, 43(5): 801-809.
- [5] NASERI F, FARJAH E, GHANBARI T, et al. Online parameter estimation for supercapacitor state-of-energy and state-of-health determination in vehicular applications[J]. IEEE Transactions on Industrial Electronics, 2020, 67(9): 7963-7972.
- [6] 董浩, 毛玲, 赵晋斌. 基于充电数据片段和GA-ELM的锂电池SOH在线估计[J]. 供用电, 2022, 39(7): 25-31.
DONG Hao, MAO Ling, ZHAO Jinbin. Online estimation of lithium battery SOH based on charging data fragment and GA-ELM[J]. Distribution & Utilization, 2022, 39(7): 25-31.
- [7] 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.
- [8] GAO Y, LIU K, ZHU C, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model[J]. IEEE Transactions on Industrial Electronics, 2020, 69(3): 2684-2696.
- [9] 蔡涛, 张钊诚, 袁奥特, 等. 锂离子电池储能安全管理中的机器学习方法综述[J]. 电力系统保护与控制, 2022, 50(24): 178-187.
- CAI Tao, ZHANG Zhaocheng, YUAN Aote, et al. Review of machine learning for safety management of li-ion battery energy storage[J]. Power System Protection and Control, 2022, 50(24): 178-187.
- [10] LIU W, XU Y. Data-driven online health estimation of li-ion batteries using a novel energy-based health indicator[J]. IEEE Transactions on Energy Conversion, 2020, 35(3): 1715-1718.
- [11] OBEID H, PETRONE R, CHAOUI H, et al. Higher order sliding-mode observers for state-of-charge and state-of-health estimation of lithium-ion batteries[J]. IEEE Transactions on Vehicular Technology, 2023, 72(4): 4482-4492.
- [12] CAI L, MENG J, STROE D I, et al. Multi-objective optimization of data-driven model for lithium-ion battery SOH estimation with short-term feature[J]. IEEE Transactions on Power Electronics, 2020, 35(11): 11855-11864.
- [13] 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. Joint estimation method of SOH and RUL of lithium-ion battery based on health characteristic parameters[J]. Proceedings of the CSEE, 2022, 42(4): 1523-1534.
- [14] 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.
- [15] GUO P, ZE C, YANG L. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction[J]. Journal of Power Sources, 2019, 412(1): 442-450.
- [16] 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.
- [17] 邓伟锋, 李振璧. 基于 GA 优化 BP 神经网络的微电网蓄电池健康状态评估[J]. 电测与仪表, 2018, 55(21): 56-60.
- DENG Weifeng, LI Zhenbi. Estimation of SOH for microgrid battery based on GA optimized BP neural network[J]. Electrical Measurement & Instrumentation, 2018, 55(21): 56-60.
- [18] LI N, HE F, MA W, 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.
- [19] 何浩然, 丁稳房, 吴铁洲, 等. 基于 IGA-BP 神经网络的锂电池健康状态估算[J]. 电源技术, 2022, 46(1): 78-82.
- HE Haoran, DING Wenfang, WU Tiezhou, et al. SOH estimation of lithium battery based on IGA-BP neural network[J]. Chinese Journal of Power Sources, 2022, 46(1): 78-82.
- [20] 徐元中, 曹翰林, 吴铁洲. 基于 SA-BP 神经网络算法的电池 SOH 预测[J]. 电源技术, 2020, 44(3): 341-345.
- XU Yuanzhong, CAO Hanlin, WU Tiezhou. Estimation of SOH for battery on SA-BP neural network[J]. Chinese Journal of Power Sources, 2020, 44(3): 341-345.
- [21] 王萍, 张吉昂, 程泽. 基于最小二乘支持向量机误差补偿模型的锂离子电池健康状态估计方法[J]. 电网技术, 2022, 46(2): 613-623.
- WANG Ping, ZHANG Ji'ang, CHENG Ze. State of health estimation of li-ion battery based on least squares support vector machine error compensation model[J]. Power System Technology, 2022, 46(2): 613-623.
- [22] XU P, XU X, LIU B, et al. Hierarchical estimation model of state-of-charge and state-of-health for power batteries considering current rate[J]. IEEE Transactions on Industrial Informatics, 2022, 18(9): 6150-6159.
- [23] 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. Online estimation of lithium-ion battery state of health using grey neural network[J]. Power System Technology, 2017, 41(12): 4038-4044.
- [24] SAHA B, GOEBEL K. Battery data set[R]. California, US: NASA Ames Prognostics Data Repository, 2007.
- [25] 冯凯, 贺东风, 徐安军, 等. 基于 Kmeans - BP 神经网络的 KR 工序终点铁水硫含量预测模型[J]. 工程科学学报, 2023, 45(7): 1187-1193.
FENG Kai, HE Dongfeng, XU Anjun, et al. End sulfur content prediction method of molten iron in KR based on Kmeans-BP neural network[J]. Chinese Journal of Engineering, 2023, 45(7): 1187-1193.
- [26] 李源, 李凤婷, 王森, 等. 基于改进变异系数法与 BP 神经网络的售电公司信用评估[J]. 电网技术, 2022, 46(11): 4228-4237.
LI Yuan, LI Fengting, WANG Sen, et al. Credit evaluation of electricity sales companies based on improved coefficient of variation method and BP neural network[J]. Power System Technology, 2022, 46(11): 4228-4237.
- [27] 马得银, 孙波, 刘澈. 基于天气信息的短期冷热电负荷联合预测方法[J]. 电网技术, 2021, 45(3): 1015-1022.
MA Deyin, SUN Bo, LIU Che. Short-term cooling and heating power load prediction method based on multi-weather information[J]. Power System Technology, 2021, 45(3): 1015-1022.
- [28] 冷晟, 付有为, 马万太, 等. 基于 GA-BP 神经网络的喷射成形锭坯形貌调控技术[J]. 华南理工大学学报(自然科学版), 2023, 51(2): 27-34.
LENG Sheng, FU Youwei, MA Wantai, et al. Study on the morphology control technology of spray forming ingot billets based on GA-BP neural network[J]. Journal of South China University of Technology (Natural Science Edition), 2023, 51(2): 27-34.
- [29] 张振坤, 张冬梅, 李江, 等. 基于多头自注意力机制的 LSTM-MH-SA 滑坡位移预测模型研究[J]. 岩土力学, 2022, 43(增刊 2): 477-486, 507.
ZHANG Zhenkun, ZHANG Dongmei, LI Jiang, et al. LSTM-MH-SA landslide displacement prediction model based on multi-head self-attention mechanism[J]. Rock and Soil Mechanics, 2022, 43(S2): 477-486, 507.
- [30] 弋佳东, 杨洁. 基于 IFOA-SA-BP 神经网络的雷达信号识别[J]. 系统工程与电子技术, 2020, 42(12): 2735-2741.
YI Jiadong, YANG Jie. Radai signal recognition based on IFOA-SA-BP neural network[J]. Systems Engineering and Electronics, 2020, 42(12): 2735-2741.
- [31] 史凯钰, 张东霞, 韩肖清, 等. 基于 LSTM 与迁移学习的光伏发电功率预测数字孪生模型[J]. 电网技术, 2022, 46(4): 1363-1372.
SHI Kaiyu, ZHANG Dongxia, HAN Xiaoqing, et al. Digital twin model of photovoltaic power generation prediction based on LSTM and transfer learning[J]. Power System Technology, 2022, 46(4): 1363-1372.
- [32] HOW D, HANNAN M, LIPU M, et al. State-of-charge estimation of li-ion battery in electric vehicles: a deep neural network approach[J]. IEEE Transactions on Industry Applications, 2020, 56(5): 5565-5574.

收稿日期: 2024-03-04; 修回日期: 2024-07-19

作者简介:

吴青峰(1987—), 男, 通信作者, 博士, 副教授, 研究方向为储能系统参数估算及均衡技术、人工智能在电网中的应用; E-mail: 827211907@qq.com

杨艺涛(1999—), 女, 硕士研究生, 研究方向为锂电池储能系统参数状态估计. E-mail: yangyitao@stu.tyust.edu.cn

(编辑 许威)