

DOI:10.19651/j.cnki.emt.2314575

基于 ASSA-RBF 联合算法的三元锂离子电池 SOC 估计

刘 齐 吴松荣 邓鸿杨 张翰文 付 聪 柳 博

(磁浮技术与磁浮列车教育部重点实验室(西南交通大学电气工程学院)成都 611756)

摘要: 准确估计三元锂电池的荷电状态(SOC)是保障电动汽车安全稳定运行的基础。针对传统 BP 神经网络估计精度不高,而 RBF 神经网络也容易陷入局部最优的问题,提出一种基于自适应麻雀搜索算法与 RBF 神经网络联合的三元锂电池 SOC 估计方法。首先,对标准麻雀搜索算法进行改进,采用精英混沌反向机制初始化麻雀种群,采用柯西-高斯变异策略优化麻雀种群中跟随者位置更新公式;然后,使用改进后的麻雀搜索算法对 RBF 神经网络的初始权值和宽度参数进行寻优,以提升算法对 SOC 的估计精度;最后,基于三元锂电池的充放电实验数据进行模型验证。结果表明,动态应力测试工况下,所提联合算法模型 SOC 估计均方根误差为 0.694%,平均百分比误差为 3.15%,能很好的应用于三元锂电池 SOC 估计。

关键词: 三元锂电池;SOC 估计;RBF 神经网络;自适应麻雀搜索算法

中图分类号: TM912 **文献标识码:** A **国家标准学科分类代码:** 470.40

SOC estimation of ternary lithium-ion battery based on ASSA-RBF joint algorithm

Liu Qi Wu Songrong Deng Hongli Zhang Hanwen Fu Cong Liu Bo

(Key Laboratory of Magnetic Suspension Technology and Maglev Vehicle, Ministry of Education (School of Electrical Engineering, Southwest Jiaotong University), Chengdu 611756, China)

Abstract: Accurately estimating the state of charge (SOC) of ternary lithium batteries is the foundation for ensuring the safe and stable operation of electric vehicles. In response to the problem of low estimation accuracy of traditional BP neural networks and the tendency of RBF neural networks to fall into local optima, this paper proposes a ternary lithium battery SOC estimation method based on the combination of adaptive sparrow search algorithm and RBF neural networks. Firstly, the standard sparrow search algorithm is improved by using the elite chaos reverse mechanism to initialize the sparrow population, and the Cauchy Gaussian mutation strategy is used to optimize the follower position update formula in the sparrow population. Then, the improved sparrow search algorithm is used to optimize the initial weight and width parameters of the RBF neural network to improve the algorithm's estimation accuracy of SOC. Finally, the model was validated based on the charging and discharging experimental data of ternary lithium batteries. The results show that under dynamic stress testing conditions, the proposed joint algorithm model has a root mean square error of 0.694% and an average percentage error of 3.15% in SOC estimation, which can be well applied to SOC estimation of ternary lithium batteries.

Keywords: ternary lithium battery;SOC estimation;RBF neural network;adaptive sparrow search algorithm

0 引言

对环境保护要求的不断提高以及近几年国际石油价格的不断攀升,促进了电动汽车技术的研究与产业化发展^[1]。动力电池约占电动汽车成本的 40%,是整车最重要的部件

之一。三元锂电池单体工作电压高、容量大且低温性能好,成为目前主流的动力电池^[2-4]。然而,其耐高温性和过充过放性能较弱,给电动汽车的安全稳定运行带来不小挑战。对三元锂电池的荷电状态进行实时精确估计有助于指导电池组的均衡控制,防止电池过充过放,从而提升使用寿命。

荷电状态(state of charge, SOC)无法直接通过测量得到,目前 SOC 估计方法主要包括安时积分法、开路电压法、基于模型的估计方法以及神经网络法^[5-6]。文献[7]综合考虑了电池自放电老化、充放电效率及电池容量等因素对 SOC 估计的影响,提出一种基于改进安时积分法的 SOC 估计方法;文献[8]将安时积分法与开电压法相结合,进一步提升 SOC 的估计精度。然而,安时积分法存在累积电流测量误差,开路电压法需要长时间电池静置条件而难以满足实时估计要求^[9]。基于模型的 SOC 估计方法主要有卡尔曼滤波法、粒子滤波法及 H 无穷滤波法等^[10]。文献[11]通过最大似然估计判断误差新息分布的变化,进而更新误差新息序列以自适应调整扩展卡尔曼滤波算法中的噪声协方差矩阵;文献[12]通过差分进化算法实现了不同环境温度下噪声协方差矩阵的自适应调节。基于模型的 SOC 估计方法严重依赖对电池的精确建模以及对电池参数的准确辨识^[13-14],操作过程复杂繁琐。神经网络法不需要建立复杂的电路模型,同时能够保证较高的估计精度。文献[15]采用自适应学习率和动量学习因子改进了基于反向传播(back propagation, BP)神经网络的 SOC 估计模型;文献[16]提出基于 python 编程的自适应动量项 BP 神经网络,使算法的收敛速度提升了 80%;文献[17]提出一种基于改进灰狼优化算法优化 BP 神经网络的锂电池 SOC 估计方法,显著提高了模型的估计精度。然而,基于 BP 神经网络的 SOC 估计模型存在一定局限性,使得模型的估计性能难以进一步提升。径向基函数(radial basis function, RBF)神经网络作为局部逼近型网络,其逼近精度、收敛速度及分类能力等方面均优于 BP 神经网络,但基于 RBF 神经网络的 SOC 估计模型易陷入局部最优和收敛精度有待提高的问题仍亟待解决。

因此,本文提出基于自适应麻雀搜索算法(adaptive sparrow search algorithm, ASSA)与 RBF 神经网络联合的 SOC 估计方法。针对麻雀搜索算法(sparrow search algorithm, SSA)初始种群随机生成导致算法收敛性能差的问题,采用精英混沌反向学习初始化麻雀种群,增强算法的全局搜索能力。针对 SSA 算法在迭代过程中种群多样性骤降的问题,采用柯西-高斯变异策略对跟随者进行变异,并通过余弦函数自适应调整变异范围,增加种群多样性的同时加快算法的收敛过程。基于实验采集的数据对比分析 BP、RBF、SSA-RBF 以及 ASSA-RBF 4 种 SOC 估计模型,结果表明所提 ASSA-RBF 联合算法 SOC 估计模型具有良好的准确性和鲁棒性。

1 基于 RBF 神经网络的 SOC 估计

1.1 RBF 神经网络

RBF 神经网络是典型的前馈式局部逼近网络,具有 3 层网络结构,包括输入层、隐藏层和输出层。输入层用于数据传输,隐藏层的作用是通过激活函数把线性不可分的低

纬度向量映射成线性可分的高纬度向量^[18],输出层用于对传输过来的数据序列作加权处理^[19]。因此,输入层到隐藏层为非线性变化,隐藏层到输出层为线性变化,这样的网络结构使得 RBF 神经网络适合处理非线性时间序列预测问题,这对于三元锂电池 SOC 估计具有适用性。其拓扑结构如图 1 所示。

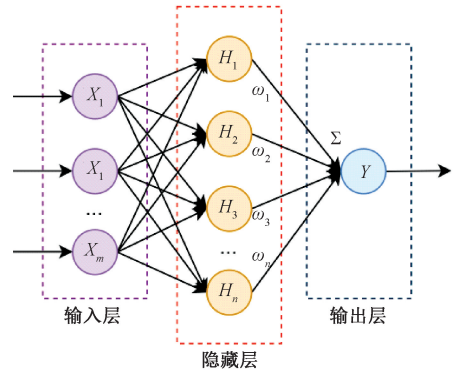


图 1 RBF 神经网络拓扑结构

选取高斯核函数作为 RBF 神经网络隐藏层神经元的激活函数,即:

$$K(\|x - x_i\|) = \exp\left[-\frac{(\|x - x_i\|)^2}{2\sigma_i^2}\right] \quad (1)$$

式中: K 表示径向基函数; x 为输入的数据序列; x_i 为隐藏层第 i 个神经元核函数的聚类中心; σ_i 为隐藏层第 i 个神经元核函数的宽度参数,控制函数的径向作用范围。RBF 神经网络的输出为:

$$Y = \sum_{m=1}^Q \omega_m \cdot K(\|x - x_m\|) \quad (2)$$

式中: Y 为网络输出; Q 为隐藏层神经元个数; ω_m 为隐藏层第 m 个神经元与输出神经元之间的连接权值。

1.2 基于 RBF 的 SOC 估计模型

锂电池的荷电状态是指在一定温度和充放电倍率下,电池当前容量与额定容量之比,可以表示为:

$$SOC = \frac{C_r}{C_N} \quad (3)$$

式中: C_r 为电池的当前剩余容量; C_N 为电池的最大可用容量。

搭建基于 RBF 的 SOC 估计模型,以电压、电流作为模型输入。输入数据序列中若是存在较大数值的数据,会削弱数值较小数据对网络训练的效果,因此需要先对输入数据进行归一化处理,整体的 SOC 估计流程如图 2 所示。

将实验采集的数据序列分为训练集和测试集。首先,将训练集进行归一化后输入到模型中进行网络训练;然后,将测试集进行归一化后输入到训练好的网络模型得到估计的 SOC 值。

2 基于 ASSA-RBF 联合算法的 SOC 估计

RBF 网络的宽度参数和初始输出权值选取不当容易

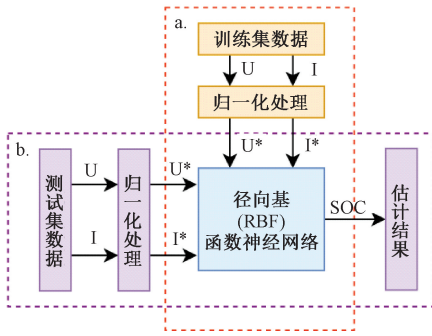


图 2 基于 RBF 的 SOC 估计流程

导致算法陷入局部最优状态。采用改进后的 SSA 算法对 RBF 网络的宽度参数和初始权值进行寻优,以提升 SOC 的估计模型的精度和鲁棒性。

2.1 标准 SSA 算法

群体智能优化算法是一类受到自然界生物群体行为和智能启发的优化算法。这类算法通过模拟群体中个体之间的交流、协作和竞争等行为,以寻找最优解或近似最优解。文献[20]对鲸鱼优化算法进行了综述,针对算法收敛速度慢和收敛精度低的问题,总结分析了算法的改进策略,但该算法在求解多目标优化问题时的能力仍有待提升。文献[21]经过对比实验,证明 SSA 算法在各方面的性能要远超过包括鲸鱼优化算法在内的其他较为典型的群智能算法。

SSA 算法是通过模拟麻雀觅食行为设计的一种启发式搜索算法,通过不断更新发现者、跟随者和警戒者的位置,逐步优化解的质量。其中,发现者是适应度较好的个体,为跟随者提供搜索方向。其位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \times \text{iter}_{\max}}\right), & R_2 < ST \\ X_{i,j}^t + Q \cdot L, & R_2 \geq ST \end{cases} \quad (4)$$

式中: t 为当前迭代次数; $X_{i,j}^t$ 为当前第 i 只麻雀在第 j 维的位置; $\alpha \in (0,1)$ 为随机数; iter_{\max} 为最大迭代次数; $R_2 \in [0,1]$ 为报警值; $ST \in [0.5,1]$ 为安全阈值; Q 为服从正态分布的随机数; L 为 $1 \times \text{dim}$ 的全 1 矩阵,其中 dim 为麻雀位置信息维度。

跟随者会根据发现者提供的方向信息进行搜索,并逐渐向发现者聚集。其位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+ \cdot L, & i \leq \frac{n}{2} \end{cases} \quad (5)$$

式中: X_{worst}^t 为当前全局最差适应度个体位置; X_p^{t+1} 为目前最佳适应度个体位置; A 是一个 $1 \times \text{dim}$ 的矩阵,随机设置矩阵中每个元素的值为 -1 或 1 ; $A^+ = A^T(AA^T)^{-1}$ 。

种群中随机产生的警戒者会监视随时可能发生的危险,以便及时提醒种群做出反捕食行为。其位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t|, & f_i \neq f_b \\ X_{i,j}^t + k \cdot \left(\frac{X_{i,j}^t - X_{\text{worst}}^t}{|f_i - f_w| + \epsilon}\right), & f_i = f_b \end{cases} \quad (6)$$

式中: X_{best}^t 为当前全局最佳适应度个体位置; β 为服从标准正态分布的控制步长; $k \in [-1,1]$ 为随机数; ϵ 为极小常数,避免分母为 0; f_i 为第 i 只麻雀适应度值; f_b 为目前最佳适应度值; f_w 为目前最差适应度值。

2.2 SSA 算法改进

目前对 SSA 算法的改进方法主要包括改变种群初始化方式和优化麻雀种群的位置更新公式。文献[22]提出反向学习和柯西变异交替执行的种群初始化方式,文献[23]结合蝴蝶算法优化发现者位置更新公式,两者都在一定程度扩大了算法的搜索范围,但算法局部与全局性能不协调的问题依然存在。因此,本文采用精英混沌反向机制进一步优化初始种群质量,并采用柯西-高斯变异策略优化跟随者位置更新方式,自适应调整搜索范围,协调局部与全局搜索性能。

1) 精英混沌反向初始化策略

标准 SSA 算法随机生成的初始种群在搜索区域内分布不均,这很大程度上降低了算法在迭代早期的探索能力,并且会引起算法的不确定性。混沌映射能够产生大量性能优越的混沌序列,是确定性与随机性的完美结合^[24],适合用来初始化麻雀种群。Logistic、Tent、Sine 及 Logistic-tent 这四种常见混沌映射的均匀性对比如图 3 所示。

由图 3 可知,Logistic-tent 和 Tent 都具有很好的映射均匀性。Logistic-tent 作为复合型混沌,兼具 Logistic 复杂的混沌动力学特性与 Tent 高度的自相关性和均匀性^[25],其映射表达式为:

$$E_{k+1} = \begin{cases} (rE_k(1-E_k) + E_k \frac{(4-r)}{2}) \bmod 1, & E_k < 0.5 \\ (rE_k(1-E_k) + (1-E_k) \frac{(4-r)}{2}) \bmod 1, & E_k \geq 0.5 \end{cases} \quad (7)$$

式中: $r \in (0,4)$ 为控制参数。本文选择 Logistic-tent 混沌并结合精英反向机制实现初始化操作,进一步提升初始麻雀种群的质量,反向解生成公式为:

$$V^* = \frac{v_{\min_i} + v_{\max_i}}{2} + \frac{v_{\min_i} + v_{\max_i}}{2k} - \frac{V_i}{k} \quad (8)$$

式中: V^* 为反向解; v_{\min_i} 和 v_{\max_i} 为麻雀种群第 i 维边界的最小和最大值; V_i 为原始解; k 为缩放系数。

具体初始化操作流程为:通过式(7)映射得到的混沌种群,带入式(8)得到反向解种群,将混沌种群和反向解种群中的所有个体进行适应度值排序,选出前 50% 的个体作为初始麻雀种群。

2) 自适应柯西-高斯变异策略

标准 SSA 算法中,跟随者的显著趋同性会导致算法在

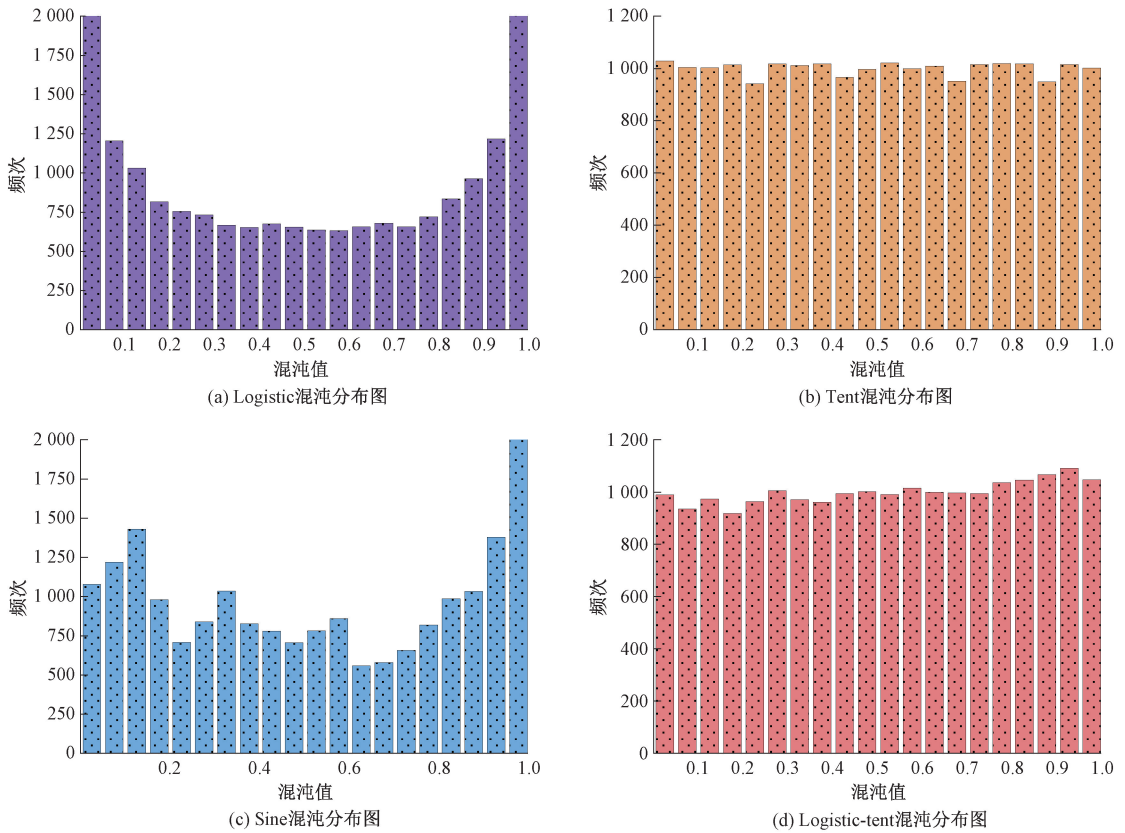


图 3 4 种混沌均匀性对比

全局范围内勘探能力减弱。由式(5)可知,目前最优解和全局最差解是影响跟随者位置更新的主要因素。一旦发现者陷入局部极值,跟随者将迅速聚集,极可能错过对潜在最优解的探索,使算法陷入局部极值而难以逃逸。为此,采用柯西-高斯变异策略给跟随者增加一个随机步长,并通过余弦函数自适应调整变异范围,变异公式为:

$$Z' = Z(1 + \lambda_1 \cdot Gauss(0,1) + \lambda_2 \cdot Cauchy(0,1)) \quad (9)$$

$$\lambda_1 = 0.5 \times \cos(\pi \times \frac{t}{T_{max}}) + 0.5 \quad (10)$$

$$\lambda_2 = -0.5 \times \cos(\pi \times \frac{t}{T_{max}}) + 0.5 \quad (11)$$

式中: Z' 为变异后跟随者位置; Z 为变异前跟随者位置; λ_1 和 λ_2 为自适应调整参数; $Gauss(0,1)$ 为服从标准高斯分布的随机数; $Cauchy(0,1)$ 为服从标准柯西分布的随机数。服从柯西分布和服从高斯分布的随机序列信号示意图如图 4 和 5 所示。

由图 4 和 5 可知,柯西变异取值范围广,具有两翼特性,而高斯变异取值范围较小。由式(10)及(11)可知,柯西变异在迭代初期占比较大,有助于扩大算法搜索范围,帮助麻雀摆脱局部极值状态。高斯变异在迭代中后期占比较大,在丰富种群多样性的同时,有助于加速算法的收敛过程。

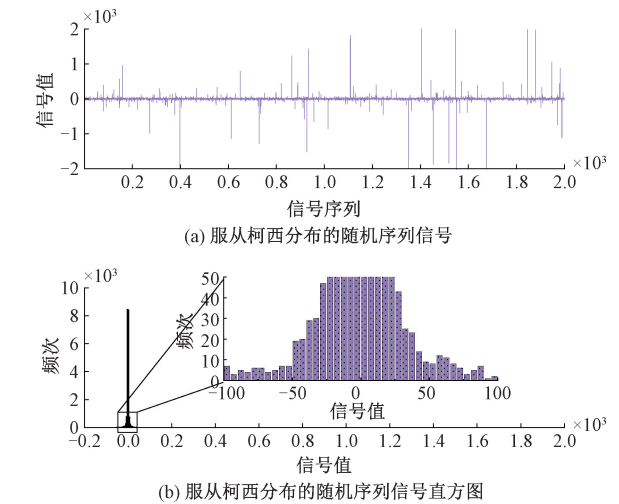




图 4 标准柯西分布信号示意图

2.3 基于 ASSA-RBF 的 SOC 估计模型

聚类中心、宽度参数和初始输出权值的选取会极大影响网络的收敛精度和稳定性。K-means 算法通过计算样本间的欧氏距离来判断样本间的相似程度,从而对样本集合进行聚类。采用 K-means 算法得到各隐藏层神经元的聚类中心,并通过 ASSA 算法与 RBF 网络联合的方法搭建 SOC 估计模型,寻找最优的宽度参数和初始权值提升估



(a) 服从高斯分布的随机序列信号



(b) 服从高斯分布的随机序列信号直方图

图 5 标准高斯分布信号示意图

计模型的性能。估计流程如图 6 所示。

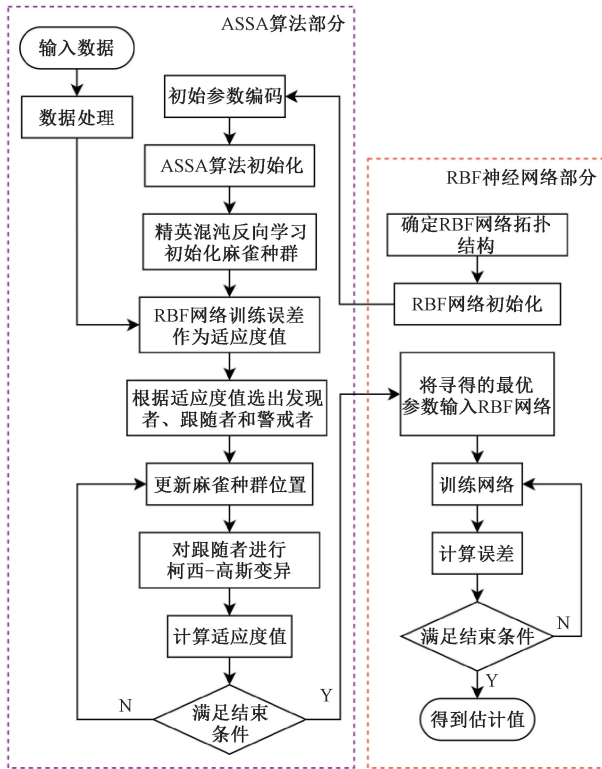


图 6 基于 ASSA-RBF 联合算法的 SOC 估计流程

由图 6 可知,ASSA-RBF 估计的主要步骤如下:

- 1) 数据处理。对采集的实验数据序列进行归一化处理。
- 2) RBF 网络初始化。搭建 RBF 网络模型并设置网络参数,通过 K-means 算法得到聚类中心,并随机设置模型的宽度参数和初始权重。
- 3) ASSA 算法优化 RBF 网络。首先,设置 ASSA 算法参数并初始化麻雀种群;其次,计算适应度值并评选出发现者、跟随者和警戒者;然后,对跟随者进行变异操作;最

后,判断是否满足终止条件,若满足则将结果赋予 RBF 模型,否则继续迭代。

4) ASSA-RBF 模型训练与预测。将 ASSA 算法寻得的最优参数带入 RBF 网络中进行训练,最后通过测试集对训练完成的模型进行测试。

3 基于实验数据的模型验证

3.1 数据获取

动态应力测试(dynamic stress testing, DST)工况作为最常用的电动汽车模拟工况之一,在性能评估领域应用广泛。为验证所提联合算法的实际估计性能,以 18650 型三元锂电池为实验对象,参考设备使用手册,分别在 25℃、35℃ 和 45℃ 条件下通过 CT-4008 型充放电测试仪进行充放电实验,采集 DST 工况试验数据,电池具体参数如表 1 所示。

表 1 电池主要参数

参数	数值
额定电压	3.7 V
额定容量	2 Ah
寿命	800~1 200 循环
充电截止电压	4.2 V
放电截止电压	3.2 V

25℃ 下 DST 工况的电流和电压曲线分别如图 7 和 8 所示。

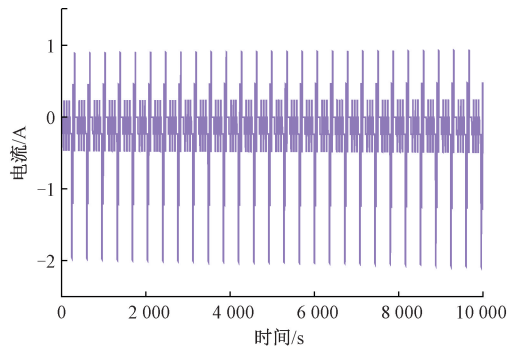


图 7 DST 工况电流曲线




图 8 DST 工况电压曲线

实验得到的 DST 工况数据共 3 780 组,将其中 3 402 组作为训练集,余下 378 组作为测试集。

3.2 模型验证分析

为更好地评价模型估计性能,本文选取均方根误差 (E_{RMSE})和平均百分比误差 (E_{MAPE})作为估计模型的评价指标,表达式如下:

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i - O_i)^2} \quad (12)$$

$$E_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{T_i - O_i}{T_i} \right| \times 100\% \quad (13)$$

式中: N 为样本数; T_i 为真实值; O_i 为估计值。

1) 模型参数设置

在 MATLAB 软件中搭建基于 BP、RBF、SSA-RBF 以及 ASSA-RBF 算法的 SOC 估计模型。各算法模型的参数设置如表 2 所示。

表 2 模型参数设置

项目	ASSA-RBF	SSA-RBF	RBF	BP
输入神经元个数	2	2	2	2
输出神经元个数	1	1	1	1
隐含神经元个数	40	40	40	10
最大迭代次数	1 000	1 000	1 000	1 000
学习率	0.01	0.01	0.01	0.01
误差容限	0.000 1	0.000 1	0.000 1	0.000 1

ASSA-RBF 模型与 SSA-RBF 模型中,设置麻雀搜索算法的最大迭代次数为 20,初始麻雀个数为 60,安全阈值为 0.6。

2) 25 °C DST 工况下模型估计性能分析

为测试模型的 SOC 估计性能,基于 25 °C 下采集的 DST 工况数据对各模型进行对比验证,结果如图 9 所示。

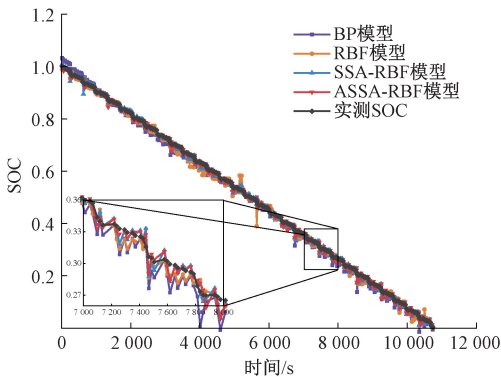


图 9 不同模型的估计曲线

由图 9 可知,基于 BP 和 RBF 模型的 SOC 估计结果相较于另外两种联合算法模型波动幅度较大,且 RBF 模型的个别估计结果存在较大误差。图 10 为各模型分别进行 10 次独立 SOC 估计的 E_{RMSE} 对比。




图 10 各模型 10 次估计 ERMSE 对比

由图 10 可知,这 4 种估计模型中,ASSA-RBF 模型的估计精度和稳定性最好,估计均方根误差基本维持在 0.007 附近。SSA-RBF 模型的估计精度和稳定性次之,BP 模型和 RBF 模型最差。各模型 10 次的误差均值如表 3 所示。

表 3 不同模型的估计性能评估

模型	$E_{RMSE} / \%$	$E_{MAPE} / \%$
BP	1.522	6.273
RBF	1.421	5.020
SSA-RBF	0.917	4.198
ASSA-RBF	0.694	3.150

由表 3 可知,RBF 模型的估计精度明显优于 BP 模型。ASSA-RBF 模型估计的 E_{RMSE} 与 E_{MAPE} 最低,其中 E_{RMSE} 相较于 SSA-RBF 模型和 RBF 模型分别降低了 24.32% 和 51.16%, E_{MAPE} 分别降低了 24.96% 和 37.25%。

综上所述,虽然 RBF 模型的估计性能优于 BP 模型,但仍存在估计精度较低以及稳定性较差的问题。基于 SSA 与 RBF 联合算法的 SOC 估计模型在估计精度和稳定性上都有较大提升,但算法在估计过程中易陷入局部极值,难以找到最优解。改进后的 ASSA-RBF 模型估计精度和稳定性都进一步得到提升。

3) 不同温度 DST 工况下模型估计性能分析

为测试不同温度下各模型的估计适应性能,利用恒温箱将电池运行的环境温度分别控制在 25 °C、35 °C 和 45 °C,并采集不同温度下的 DST 工况数据对各估计模型进行对比分析。35 °C 和 45 °C 环境温度下各模型的估计结果如图 11 和 12 所示,图 13 为各模型在不同温度下估计的 E_{RMSE} 直方图。

由图 11 和 12 可知,在 35 °C 下 BP 模型和 RBF 模型最大估计误差绝对值均超过 0.065;在 45 °C 下 BP 模型最大估计误差绝对值接近 0.065,而 RBF 模型超过 0.1。在两种环境温度下,ASSA-RBF 模型和 SSA-RBF 模型的估计误差绝对值基本维持在 0.03 以内,最大为 0.04。这两种




图 11 35 °C 温度下各模型估计结果


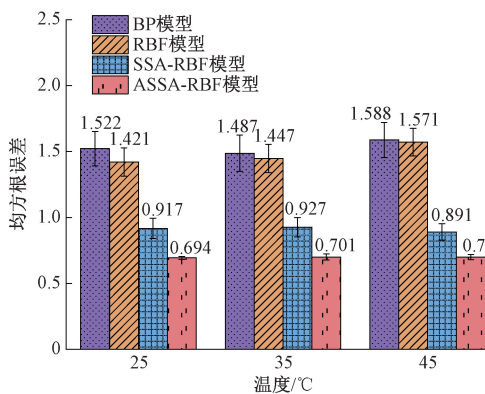


图 12 45 °C 温度下各模型估计结果

图 13 不同温度下估计 E_{RMSE} 对比

联合算法估计模型对前半段 SOC 估计精度要略高于后半段。

由图 13 可知,不同温度下 BP 模型的误差棒最长,稳定性最差。RBF 模型估计性能优于 BP 模型,在 45 °C 下 E_{RMSE} 均值与 BP 模型接近,这两种模型的估计精度受温度影响较大。SSA-RBF 模型的估计性能较之传统模型有较

大提升,但几次独立 SOC 估计的 E_{RMSE} 离散程度较大。各温度下 ASSA-RBF 模型的误差棒都最短,估计稳定性最好,其均方根误差的平均值基本在 0.7 上下小范围内浮动。

综上所述,本文所提 ASSA-RBF 联合算法具有良好的延展泛化能力,其在不同温度下的 SOC 估计结果表现出良好的准确性和鲁棒性。

4 结 论

针对三元锂电池 SOC 估计对模型估计精度高的要求,本文提出基于 ASSA-RBF 联合算法的 SOC 估计模型。根据实验测得的 DST 工况数据,对搭建的 4 种 SOC 估计模型进行对比,得到结论如下:

本文提出的 ASSA 算法,能有效解决传统 SSA 算法易陷入局部极值的问题,提升算法的收敛精度和稳定性。ASSA 与 RBF 构成的联合算法能够效提升三元锂电池 SOC 的估计精度。

ASSA-RBF 联合算法模型在 DST 工况下的 SOC 估计性能明显优于 BP 模型、RBF 模型和 SSA-RBF 模型。

在不同温度条件下,ASSA-RBF 模型表现出优良的估计准确性和鲁棒性,有利于三元锂电池 SOC 的估计。

参考文献

- [1] 罗桂成,盛春龙. 浅析新能源汽车的未来发展趋势[J]. 时代汽车,2022(21):105-107.
- [2] 呼升. 三元锂电池在新能源汽车上的设计与应用[J]. 时代汽车,2022(14):122-124.
- [3] SU Y. comparative analysis of lithium iron phosphate battery and ternary lithium battery[J]. Journal of Physics: Conference Series,2022,2152(1):012056.
- [4] WU K. Development status and prospects of lithium-ion power batteries for electric vehicles [J]. International Journal of Chemical Engineering and Applications,2021,12(4).
- [5] 李军,李虎林. 电动汽车锂离子电池荷电状态估算方法综述[J]. 科学技术与工程,2022,22(6):2147-2158.
- [6] YAO J X,DING J,CHENG Y Y,et al. Sliding mode-based H-infinity filter for SOC estimation of lithium-ion batteries[J]. Ionics,2021,27:5147-5157.
- [7] ZHANG M Y, FAN X B. Design of battery management system based on improved ampere-hour integration method [J]. International Journal of Electric and Hybrid Vehicles,2022,14(1-2):1-29.
- [8] 续远. 基于安时积分法与开路电压法估测电池 SOC[J]. 新型工业化,2022,12(1):123-124.
- [9] ZHENG F D,XING Y J,JIANG J C,et al. Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries[J]. Applied Energy,2016,183.

- [10] 谭必蓉,杜建华,叶祥虎,等. 基于模型的锂离子电池 SOC 估计方法综述[J]. 储能科学与技术, 2023, 12(6):1995-2010.
- [11] 袁正峰,郭兴众,花晓飞. 基于改进的 AEKF 铅酸电池 SOC 在线估计[J]. 电子测量与仪器学报, 2023, 37(2):228-235.
- [12] ZHAO M X. An improved ekf algorithm for soc estimation of lithium battery considering temperature effects[J]. Journal of Physics: Conference Series, 2022, 2395(1):012070.
- [13] WANG Q Q, WANG J, ZHAO P J, et al. Correlation between the model accuracy and model-based SOC estimation[J]. Electrochimica Acta, 2017, 228.
- [14] LIAN G Q, YE M, WANG Q, et al. A BP neural network-ant lion optimizer and UKF method for SOC estimation of lithium-ion batteries [J]. Journal of Physics: Conference Series, 2022, 2369(1):012072.
- [15] 李江江,冯丽娟. 改进的 BP 神经网络在电动汽车锂电池 SOC 估算中的研究[J]. 汽车实用技术, 2018(21): 19-21.
- [16] 姚和友,张庭芳,黄菊花,等. 改进的动量项 BP 神经网络电池 SOC 估算[J]. 电池, 2019, 49(4):308-311.
- [17] 于仲安,邵昊晖,陈可怡. 基于 IGWO-BP 神经网络的锂离子电池 SOC 估计[J]. 电源技术, 2023, 47(9): 1153-1157.
- [18] LIU H, ZHOU G, ZHOU Y Q, et al. An RBF neural network based on improved black widow optimization algorithm for classification and regression problems[J]. Frontiers in Neuroinformatics, 2023, 16.
- [19] 付诗意,吕桃林,闵凡奇,等. 电动汽车用锂离子电池 SOC 估算方法综述[J]. 储能科学与技术, 2021, 10(3):1127-1136.
- [20] 许德刚,王再庆,郭奕欣,等. 鲸鱼优化算法研究综述[J]. 计算机应用研究, 2023, 40(2):328-336.
- [21] 李雅丽,王淑琴,陈倩茹,等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1-12.
- [22] 毛清华,张强. 融合柯西变异和反向学习的改进麻雀算法[J]. 计算机科学与探索, 2021, 15(6):1155-1164.
- [23] 张伟康,刘升,任春慧. 混合策略改进的麻雀搜索算法[J]. 计算机工程与应用, 2021, 57(24):74-82.
- [24] ARORA S, ANAND P. Chaotic grasshopper optimization algorithm for global optimization [J]. Neural Computing and Applications, 2019, 31(8).
- [25] 秦秋霞,梁仲月,徐毅. 基于 Logistic-Tent 混沌映射和位平面的图像加密算法[J]. 大连民族大学学报, 2022, 24(3):245-252.

作者简介

刘齐, 硕士研究生, 主要研究方向为锂电池荷电状态估计、机器学习等。

E-mail: 1203954416@qq.com

吴松荣(通信作者), 博士, 副教授, 主要研究方向为电力电子技术、机车/动车组牵引传动等。

E-mail: srwu88@163.com