

# 基于麻雀优化算法的锂电池健康状态估计方法

王超<sup>1</sup>, 陈奇<sup>2</sup>, 谷新梅<sup>2</sup>, 姜湖<sup>3</sup>, 郭芳<sup>4</sup>, 黄广山<sup>4,✉</sup>, 祝姗姗<sup>4</sup>

(1. 广州南方投资集团有限公司, 广东 广州 510663; 2. 中国能源建设集团广东省电力设计研究院有限公司, 广东 广州 510663;  
3. 广东科诺勘测工程有限公司, 广东 广州 510663; 4. 佛山科学技术学院 机电工程与自动化学院, 广东 佛山 528000)

**摘要:** [目的] 准确估计锂离子电池健康状态 (SoH) 对于未来的智能电池管理系统具有重要意义。为解决数据特征质量差以及模型参数调整困难的问题, 提出了基于奇异值定阶降噪以及麻雀算法优化门控循环 (GRU) 神经网络的锂电池 SoH 估计方法。[方法] 首先, 从电池充放电数据中提取了 3 个与 SoH 衰减高度相关的指标, 运用奇异值分解技术对特征进行降噪, 提高了其与 SoH 的相关性。接着, 使用麻雀搜索算法优化 GRU 神经网络的模型结构及参数, 提高其对 SoH 的估计精度。最后, 使用先进生命周期工程中心 (CALCE) 的电池数据集验证所提模型的有效性。[结果] 实验结果表明, 所提模型适用于电池 SoH 估计, 其最大均方根误差 (RMSE) 仅为 0.018 4; 经过数据降噪以及算法优化后的 GRU 模型, 其 RMSE 比初始模型减少了 55.41%。[结论] 文章所提方法实现了 SoH 的准确估计, 可为实际工程应用提供参考。

**关键词:** 锂电池; 健康状态; 数据降噪; 麻雀算法; 神经网络

中图分类号: TK01; TM912

文献标志码: A

文章编号: 2095-8676(2023)06-0089-09

开放科学 (资源服务) 二维码:



## Assessment Method for Health State of Li-Ion Batteries Based on Sparrow Search Algorithm

WANG Chao<sup>1</sup>, CHEN Qi<sup>2</sup>, GU Xinmei<sup>2</sup>, JIANG Hu<sup>3</sup>, GUO Fang<sup>4</sup>, HUANG Guangshan<sup>4,✉</sup>, ZHU Shanshan<sup>4</sup>

(1. Guangzhou Southern Investment Group Co., Ltd., Guangzhou 510663, Guangdong, China;  
2. China Energy Engineering Group Guangdong Electric Power Design Institute Co., Ltd., Guangzhou 510663, Guangdong, China;  
3. Guangdong Kenuo Surveying Engineering Co., Ltd., Guangzhou 510663, Guangdong, China;  
4. School of Mechatronic Engineering and Automation, Foshan University, Foshan 528000, Guangdong, China)

**Abstract:** [Introduction] Accurate estimation of the Li-ion batteries' State of Health (SoH) is essential for future intelligent battery management systems. To solve the problems of poor quality of data features and difficulties in adjusting model parameters, this study proposes a method for estimating the SoH of lithium batteries based on singular value fixed-order noise reduction and the sparrow search algorithm which can optimize the gated recurrent unit (GRU) neural network. [Method] Firstly, three indicators highly correlated with SoH decay were extracted from the battery charge and discharge data. Noise reduction was applied to the features using singular value decomposition techniques to improve their correlation with SoH. Next, using the sparrow search algorithm to optimize the model structure and parameters of the GRU neural network improve the accuracy of estimation of SoH. Finally, the battery data sets from Centre for Advanced Life Cycle Engineering (CALCE) were used to verify the validity of the proposed model. [Result] The experimental results show that the model proposed in this study applies to the battery SoH estimation, with a maximum root mean square error (RMSE) of only 0.018 4. After data noise reduction and algorithm optimization, the RMSE of the GRU model is reduced by 55.41% compared to the initial model. [Conclusion] The method proposed in this paper accurately estimates SoH and can be used as a reference for practical engineering applications.

**Key words:** lithium battery; state of health; data noise reduction; sparrow search algorithm; neural network

2095-8676 © 2023 Energy China GEDI. Publishing services by Energy Observer Magazine Co., Ltd. on behalf of Energy China GEDI. This is an open access article under the CC BY-NC license (<https://creativecommons.org/licenses/by-nc/4.0/>).

收稿日期: 2023-02-07 修回日期: 2023-03-08

基金项目: 广东普通高校创新团队项目“面向碳中和的智能源关键技术及应用创新团队”(2021KCXTD027); 中国能建广东院科技项目“氢能和燃料电池关键技术”(EV05021W)

## 0 引言

锂离子电池以其高能量密度和低使用成本在工程应用中普遍存在,例如新能源汽车、储能电站及便携式电子产品<sup>[1-2]</sup>。然而,在长期的循环运行下,锂离子电池的性能会出现一定程度的下降,主要表现为容量衰减及功率下降。电池性能下降还可能导致系统故障甚至严重事故,例如火灾和爆炸<sup>[3-4]</sup>。健康状态(State of Health, SoH)反映了电池当前存储和供应能量/功率的能力相对于其寿命开始时的水平,是锂电池生命周期故障和安全预警的关键参数<sup>[5]</sup>。准确、有效地估计锂电池健康状态并预测其剩余使用寿命,是提高锂电池甚至锂电平台运行可靠性的有效手段<sup>[6]</sup>。

电池 SoH 不能直接通过传感器测量,往往借助于可直接测量的参数(电压、电流、温度)进行间接估计<sup>[7]</sup>。目前,已有学者提出了许多 SoH 的估计方法,这些方法可以分为 3 类,分别为实验法、数值模型与数据驱动方法。实验方法是通过标准充放电直接测量<sup>[8]</sup>或提取特征指标估计电池容量<sup>[9-11]</sup>。但实验方法耗时长,不宜用于实际应用中电池 SoH 实时估计。基于数值模型的方法包括经验模型<sup>[12]</sup>、电化学模型<sup>[13]</sup>、等效电路模型<sup>[14]</sup>等。经验模型通过大量实验数据分析、拟合和统计处理获取 SoH 的变化规律,但难以适应实际工况变化。电化学模型使用非线性偏微分方程模拟电池内部电动力学,可以衡量不同的老化机制,但复杂的建模和计算过程在大规模应用时对计算资源的需求非常高。等效电路模型(Equivalent Circuit Model, ECM)计算量低,实时应用方便且 ECM 参数能够反映电池容量变化趋势,在 SoH 评估的应用中具有优势。但 ECM 模型无法考虑环境温度的影响,导致 SoH 估计精度较差。数据驱动方法利用电池历史工作数据挖掘容量变化的潜在规律,建模简单且具有优异非线性拟合能力。

近年来,数据驱动方法以其灵活、普适的特点成为 SoH 估计的研究热点<sup>[15]</sup>。Li 等人<sup>[16]</sup>应用先进的高斯滤波器方法来获得平滑的增量容量曲线,然后从部分增量容量曲线中提取健康指标来描述其与 SoH 之间的关系,构建了新型高斯过程回归模型用以 SoH 估计。Zhou 等人<sup>[17]</sup>从高频和中频范围阻抗谱数据中提取电池健康指标,设计了具有单步延迟反馈回路的递归高斯过程回归模型,以提供平滑且

准确的电池健康状态估计。Li 等人<sup>[18]</sup>选取了 4 个与 SoH 下降高度相关的健康特征,运用改进的蚁狮算法优化支持向量回归模型的超参数,从而提高了 SoH 估计的精度和鲁棒性。上述研究中,大多在特征选择方面做了大量的工作,却极少对提取的特征做进一步处理以提高特征与 SoH 的相关性。特征质量是电池寿命估计模型建模的重要影响因素,噪声大、相关性低的数据会影响数据驱动模型的估计效果。选择合理的特征能够减少模型的开发成本,使模型更加轻量化,提高模型的计算速度。其次,开发合理模型结构,确定有效的模型超参数,同样能够显著提高电池 SoH 预测结果。

基于上述分析,本文提出基于奇异值分解(Singular Value Decomposition, SVD)定阶降噪和麻雀搜索算法(Sparrow Search Algorithm, SSA)优化门控循环单元(Gate Recurrent Unit, GRU)神经网络的 SoH 估计方法。首先,从电池充放电数据中选取了 3 个与 SoH 衰减相关的指标,分别为恒流充电时间、恒压充电时间和放电平均电压,利用奇异值分解技术对提取的健康指标进行降噪处理,提高其与 SoH 的相关性,减少噪声对神经网络模型的干扰。然后建立基于门控循环神经网络层的数据驱动模型,并采用麻雀搜索算法对神经网络模型的超参数进行寻优,提高模型对 SoH 的预测精度。最后,本研究提出的方法在公开数据集中进行验证,并与传统方法进行比较,以表明本方法的优越性。

## 1 数据源与预处理

### 1.1 数据集来源

本研究利用先进生命周期工程中心(Centre for Advanced Life Cycle Engineering, CALCE)的电池数据集验证所提方法的有效性<sup>[14]</sup>,选用电池编号为 CS2-35, CS2-36 和 CS2-37 的测试数据。所有电池均以 0.5 C 的恒定电流速率进行充电,直到截止电压 4.2 V;接着保持 4.2 V 充电,直到电流降至 0.05 A 以下;最后以恒定 1 C 电流对电池进行放电,直到截至放电电压 2.7 V,如表 1 所示。

### 1.2 SoH 定义

SoH 是电池管理系统的关键参数,代表电池的退化程度。SoH 通常用容量或者内阻来表示,本文采用容量来表示 SoH,其定义如下式所示<sup>[19]</sup>:

表 1 电池特性表

Tab. 1 Battery characteristics

参数	规格
标称容量/mAh	1 100
化学成分	LiCoO <sub>2</sub>
充电截止电压/V	4.2
放电截止电压/V	2.7

$$\text{SoH} = \frac{Q_c}{Q_r} \times 100\% \quad (1)$$

式中:

$Q_c$  —— 电池当前容量(Ah);

$Q_r$  —— 电池标称容量(Ah)。

### 1.3 特征提取

锂电池运行过程中的电压、电流、温度、时间等数据能够直接测量的,而电池容量通常无法直接测量,只能通过其他手段进行间接估计。电池容量衰减通常用来表征电池的老化过程,因此从可直接测量数据中提取可描述不同尺度电池老化特性的特征对于估计电池健康状态至关重要<sup>[20-21]</sup>。根据对充放电曲线的观察和分析,本文选取以下 3 个特征(F1、F2 和 F3)来估算 SoH:

F1: 恒流充电时间(Constant Current Charging Time, CCCT), CCCT 变化本质上是由于锂电池材料发生了衰变,直接影响电池在恒流阶段可充电容量。随着电池老化,极化程度加剧,电池容量随使用次数不断衰减。如图 1 所示,电压不断上升的过程为恒流充电阶段,电压恒定的过程为恒压充电阶段。随着循环次数的增加,恒流充电模式的持续时间减少<sup>[22]</sup>。




图 1 CC-CV 充电曲线

Fig. 1 CC-CV charging curve

F2: 恒压充电时间(Constant Voltage Charging Time, CVCT), 恒压充电阶段随着充电电流的减小,电解液中的锂离子逐渐嵌入负极,浓度迅速降低<sup>[23]</sup>。恒压充电模式用于消除 CC 模式的极化现象,持续时间越长,电池老化越严重。如图 1 所示,随着循环次数的增加,恒压充电模型持续的时间增加, CVCT 为电池老化的逆向指标。

F3: 平均放电电压 (Average Discharge Voltage, ADV), 如图 2 所示,随着循环次数的增加,放电电压曲线往左下方移动。平均放电电压随着电池老化逐渐降低,这与 SoH 的变化趋势一致,可以看作是一种健康特征。




图 2 放电电压曲线

Fig. 2 Discharge voltage curve

Spearman 秩相关系数可用于定量分析两个变量之间联系的紧密程度。本研究使用 Spearman 秩相关系数定量分析上述指标与电池 SoH 之间的相关性。假设  $(x_1, x_2, \dots, x_n)$ ,  $(y_1, y_2, \dots, y_n)$  分别为来自总体  $X$ 、 $Y$  的样本,令  $R(x_j)$ ,  $R(y_j)$  分别表示在样本  $(x_1, x_2, \dots, x_n)$ ,  $(y_1, y_2, \dots, y_n)$  中的秩,则 Spearman 秩相关系数计算公式如下<sup>[24]</sup>:

$$r(X, Y) = 1 - \frac{6 \sum_{j=1}^n d_j^2}{n(n^2 - 1)} \quad (2)$$

式中:  $d_j = R(x_j) - R(y_j)$ ,  $j = 1, 2, \dots, n$ 。

Spearman 相关系数计算结果如表 2 所示。相关系数取值为 0.8~1, 则认为变量之间具有强相关性。CCCT、CVCT 与 ADV 在 3 个特征的相关性系数均大于 0.8, 说明本研究提取的特征适用于估计电池 SoH。

表 2 特征参数与 SoH 的 Spearman 相关系数计算结果

Tab. 2 Calculation results of the Spearman correlation coefficients of feature parameters and SoH

特征指标		CCCT	CVCT	ADV
Spearman 相关系数	CS2-35	0.992 0	-0.939 0	0.942 3
	CS2-36	0.993 3	-0.867 5	0.964 1
	CS2-37	0.983 6	-0.937 0	0.955 8

#### 1.4 数据预处理

##### 1) 奇异值定阶降噪

奇异值分解是数学里常用的矩阵分解方法, 由于其具有较好的理论基础, 近年来在数据降维、噪声控制和信号处理等方面获得了广泛的应用<sup>[25]</sup>。任意  $m \times n$  的矩阵  $A$  可以分解为如下所示<sup>[26]</sup>:

$$A = U \Sigma V^T \quad (3)$$

式中:

$U$  ——  $(m \times r)$  左奇异矩阵;

$V$  ——  $(n \times r)$  右奇异矩阵;

$\Sigma$  —— 对角矩阵, 对角线上是矩阵  $A$  的奇异值从大到小排列,  $r$  为矩阵  $A$  的秩数。

$$\Sigma = \begin{bmatrix} \sigma_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sigma_r \end{bmatrix} = \begin{bmatrix} \sqrt{\lambda_1} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sqrt{\lambda_r} \end{bmatrix} \quad (4)$$

奇异值可以表示原矩阵在其对应的特征向量上包含的信息, 奇异值越大, 说明其对应的特征向量在构成原矩阵的过程中承担的作用越大。如果  $k (k \leq r)$  个奇异值数值较大, 说明前  $k$  个奇异值对应的信息是原矩阵的主成分<sup>[27]</sup>, 可以将原矩阵重构降噪为  $\tilde{A}$ :

$$\tilde{A} = U_{m \times k} \Sigma_{k \times k} V_{n \times r}^T \quad (5)$$

经过奇异值定阶降噪后的 Spearman 相关系数计算结果如表 3 所示, 所有特征相关性系数均大于 0.9。并且经过降噪后, 所有特征的相关性系数均有一定程度的提升, 其中以 CVCT 提升最为明显。

表 3 特征降噪后的 Spearman 相关系数

Tab. 3 Spearman correlation coefficients after feature noise reduction

特征指标		CCCT	CVCT	ADV
Spearman 相关系数	CS2-35	0.994 9	-0.953 2	0.966 6
	CS2-36	0.993 4	-0.948 0	0.969 0
	CS2-37	0.981 1	-0.955 3	0.963 5

##### 2) 归一化

不同变量之间的量级会影响优化算法以及神经网络模型的拟合精度, 故将特征按照最大值最小值归一化至  $[0, 1]$  区间, 其公式为:

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (6)$$

式中:

$y$  —— 不同的变量;

$y'$  —— 归一化后的值;

$y_{\max}$  —— 变量的最大值;

$y_{\min}$  —— 变量的最小值。

## 2 数据驱动方法

### 2.1 GRU 神经网络

门控循环单元神经网络 (GRU)<sup>[28]</sup> 与长短时记忆神经网络相似, GRU 由于少了一个门, 其结构更加简单。如图 3 所示, GRU 只有两个门: 重置门和更新门, 这使得模型的参数化程度更低, 计算成本更低, 训练速度更快。重置门的作用是控制历史信息的保留, 重置门的值越大, 忽略的历史信息越少。更新门用于控制前一个单元状态和当前新输入对当前新单元状态的影响。GRU 的数学计算过程如下:

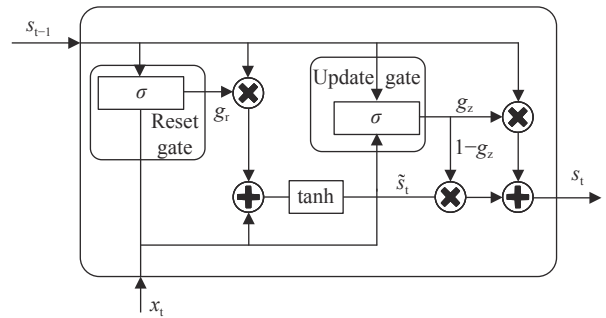


图 3 GRU 结构图

Fig. 3 GRU structure diagram

$$g_r = \sigma(W_r \cdot [s_{t-1}, x_t] + b_r) \quad (7)$$

$$g_z = \sigma(W_z \cdot [s_{t-1}, x_t] + b_z) \quad (8)$$

$$\hat{s}_t = \tanh(W_h \cdot [g_r * s_{t-1}, x_t] + b_s) \quad (9)$$

$$s_t = (1 - g_z) * s_{t-1} + g_z * \hat{s}_t \quad (10)$$

式中:

$g_r$  —— 重置门状态;

$g_z$  —— 更新门状态;

$\hat{s}_t$  —— 候选隐藏状态;

$s_t$  ——当前隐藏状态;  
 $W$  ——权重;  
 $b$  ——偏置;  
 $\sigma(\cdot)$  ——sigmoid 函数,通过这个函数可以

将数据变为 0~1 范围的数值,如式(11)所示;

$\tanh(\cdot)$  —— $\tanh$  函数,通过这个函数可以将数据变为  $[-1,1]$  范围的数值,如式(12)所示。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

$$\tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (12)$$

GRU 架构在处理长时间序列数据方面表现良好,并且可以在不同的时间步共享相同的参数。所选取的特征 CCCT、CVCT、ADV 均为一维时间序列数据,使用 GRU 来估计 SoH 是合理的。所选特征作为 GRU 神经网络的输入,SoH 作为其输出,其映射关系如下式所示:

$$\text{SoH} = f(F_1, F_2, F_3) \quad (13)$$

## 2.2 麻雀搜索算法

麻雀搜索算法<sup>[29]</sup>依据麻雀的觅食行为建立数学模型,通过有规则更新种群位置的方式,找到最优麻雀个体的位置,从而为神经网络模型找到最佳的超参数。

在觅食的过程中, $d$ 维空间内由 $n$ 个麻雀组成的种群可表示为:

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & \vdots & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix} \quad (14)$$

式中:

$x_n^d$  ——第 $n$ 个麻雀个体在第 $d$ 维空间中的参数。

麻雀种群分为发现者和跟随者,具有较高适应度值的麻雀个体选择成为发现者,引导种群进行搜索。加入者根据适应度值的变化决定是否跟随发现者,发现者位置更新规则如下式所示:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \times \exp\left(-\frac{i}{\beta \times t_{\max}}\right) & \text{if } R_2 > S_T \\ X_{i,j}^t + Q \times L & \text{if } R_2 < S_T \end{cases} \quad (15)$$

式中:

$t$  ——当前迭代次数;

$t_{\max}$  ——最大迭代次数;

$\beta$  ——补偿控制参数,是服从均值为 0,方差为 1 的正态分布的随机数;

$X_{i,j}$  ——第 $i$ 个麻雀个体在第 $j$ 维中的位置信息;

$Q$  ——服从正态分布的随机数;

$L$  ——全 1 矩阵;

$S_T$  ——安全阈值,  $S_T \in [0.5, 1]$ ;

$R_2$  ——麻雀种群位置的预警值,  $R_2 \in [0, 1]$ 。

跟随者的位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} Q \times \exp\left(\frac{X_{\text{worst}}^t - X_p^{t+1}}{t^2}\right) & \text{if } i > \frac{n}{2} \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \times A^+ \times L & \text{otherwise} \end{cases} \quad (16)$$

式中:

$X_{\text{worst}}^t$  ——全局最差麻雀位置;

$X_p$  ——发现者最优位置;

$A$  ——矩阵,其每个元素值均在区间  $[-1, 1]$  内。

从种群中随机选取 15% 的麻雀个体成为警戒者,并按照下式更新位置。通过不断更新种群位置,尽可能减小适应度函数值。

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \times |X_{i,j}^t - X_{\text{best}}^t| & f_i > f_g \\ X_{i,j}^t + K \times \left(\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i > f_w) + \varepsilon}\right) & f_i = f_g \end{cases} \quad (17)$$

式中:

$X_{\text{best}}$  ——最优麻雀个体的位置;

$\beta$  ——补偿控制参数,是服从均值为 0,方差为 1 的正态分布的随机数;

$K$  ——区间  $[-1, 1]$  之间的随机数;

$f_i$  ——当前麻雀个体的适应度值;

$f_g$ 、 $f_w$  ——当前全局最佳和最差适应度值;

$\varepsilon$  ——常数,避免分母为 0。

## 2.3 麻雀算法优化 GRU 神经网络

应用麻雀搜索算法对 GRU 神经网络模型的超参数进行优化。优化的参数包括学习率、迭代次数、神经元数量。麻雀搜索算法的初始参数包括迭代次数、种群数量和优化维度。

麻雀算法优化 GRU 神经网络步骤如图 4 所示:

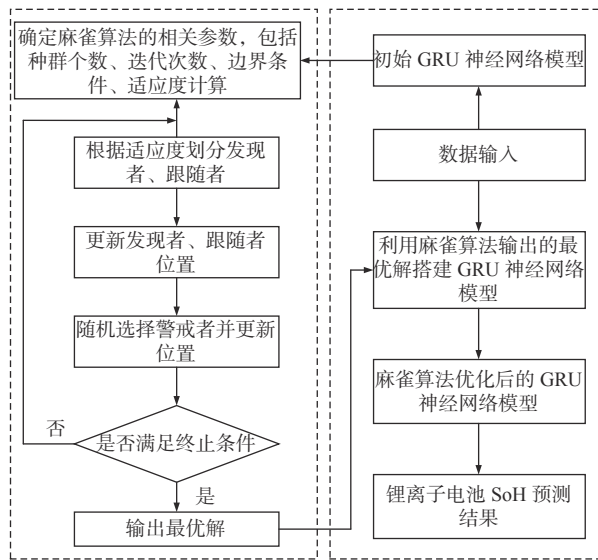


图 4 麻雀算法优化 GRU 神经网络流程

Fig. 4 The flow of optimizing the GRU neural network by sparrow search algorithm

Step 1: 初始化麻雀搜索算法麻雀种群的数量、麻雀算法迭代次数、算法寻优维度; 初始化麻雀种群的位置, 其初始种群位置为随机生成。

Step 2: 以均方根误差为适应度函数, 计算每个麻雀个体的适应度, 选择最优麻雀个体, 并根据最优麻雀个体更新麻雀种群的位置, 种群位置更新公式如式(15)~式(17)所示, 适应度函数如下式所示:

$$f_{it} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_{tru}(t) - y_{pre}(t))^2} \quad (18)$$

式中:

$y_{tru}$  —— 第  $t$  个样本的实际值;

$y_{pre}$  —— 第  $t$  个样本的预测值;

$n$  —— 样本个数。

Step 3: 重复执行 Step 2, 直至满足终止条件, 本研究算法终止条件设置为麻雀搜索算法的迭代次数。输出麻雀搜索算法的优化结果, 分别为 GRU 神经网络的学习率、迭代次数、神经元数量。

Step 4: 将麻雀搜索算法输出的参数用于 GRU 神经网络, 并用训练样本对网络进行训练, 获得锂离子电池 SoH 预测模型。

### 3 结果与讨论

本研究实验数据来源于先进生命周期工程中心 (CALCE) 的提供的电池数据集, 选用电池编号为

CS2-35, CS2-36 和 CS2-37 的测试数据。本实验选取数据的前 50% 作为训练数据, 数据的后 50% 作为测试集。为了体现本研究所提模型的优越性, 将 GRU、SVD-GRU 和 SVD-SSA-GRU 3 种模型进行了比较。

#### 3.1 评价指标

将均方根误差 (Root Mean Square Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 和平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 作为评价指标来评估模型效果。评价的指标公式如下:

$$\begin{cases} \text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_{tru}(t) - y_{pre}(t))^2} \\ \text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_{tru}(t) - y_{pre}(t)| \\ \text{MAPE} = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_{tru}(t) - y_{pre}(t)}{y_{tru}(t)} \right| \end{cases} \quad (19)$$

式中:

$y_{tru}$  —— 第  $t$  个样本的实际值;

$y_{pre}$  —— 第  $t$  个样本的预测值;

$n$  —— 样本个数。

#### 3.2 结果分析

为说明特征选择的必要性, 对 GRU 神经网络模型输入特征数量为 2 个和 3 个的情况进行了讨论。以 CS2-35 电池为例, 在相同模型参数的情况下, 不同特征数量的预测结果如图 5 所示:

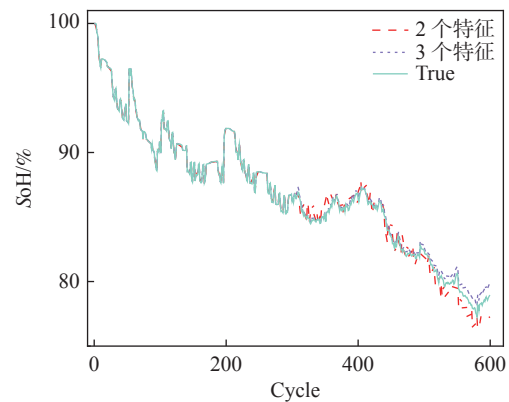


图 5 不同特征数量结果对比

Fig. 5 Comparison of results for different numbers of features

对于 CS2-35 电池, 当使用 2 个特征 (CCCT、ADV) 进行 SoH 估计时, 其 RMSE 为 0.012 0。在相同模型参数的情况下, 使用 3 个特征的 RMSE 为 0.007 3。

结果表明,使用 3 个特征时 GRU 神经网络对 SoH 的拟合效果更佳,故下文均以 3 个特征作为输入的情况进行讨论。

针对 3 组电池数据,3 种模型对其 SoH 的估计效果如图 6~图 8 所示。表 4 展示了经过麻雀算法优化后的 GRU 神经网络超参数值。为了更加准确地描述不同模型之间的精度,使用 RMSE、MAE、MAPE 进行评价,其值如表 5 所示。




图 6 CS2-35 健康状态估计结果

Fig. 6 CS2-35 health state estimation results

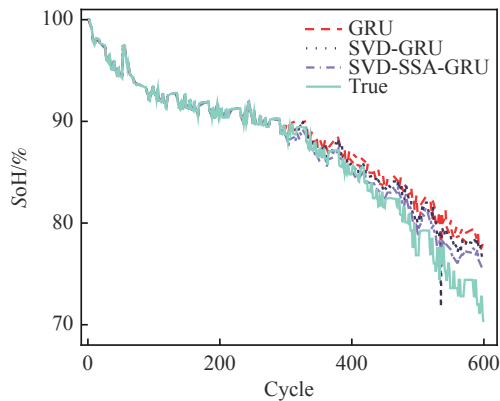


图 7 CS2-36 健康状态估计结果

Fig. 7 CS2-36 Health state estimation results

从图 6~图 8 可以看出, SVD-SSA-GRU 模型对锂离子电池 SoH 具有最好的估计效果,其估计曲线

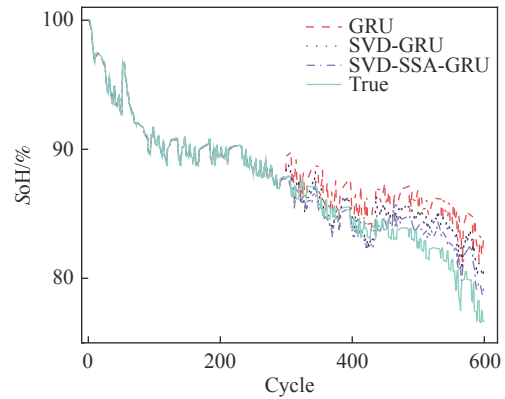


图 8 CS2-37 健康状态估计结果

Fig. 8 CS2-37 Health state estimation results

表 4 超参数值

Tab. 4 Hyperparametric value

电池	学习率	迭代次数	GRU1 神经元	GRU2 神经元
C35	$6.66 \times 10^{-3}$	65	69	89
C36	$9.04 \times 10^{-3}$	53	74	89
C37	$2.31 \times 10^{-3}$	63	92	64

与真实数据曲线更加贴合, RMSE、MAE、MAPE 均为 3 个模型中最小。同时,数据特征经过奇异值定阶降噪之后,其对于 SoH 的估计效果要优于原始数据。

具体到每个电池而言,其误差指标如表 5 所示。对于 CS2-35 电池, SVD-SSA-GRU 模型的 RMSE、MAE 分别为  $7.3 \times 10^{-3}$  和  $5.9 \times 10^{-3}$ , 比 GRU 模型降低了  $1.07 \times 10^{-2}$ 、 $8 \times 10^{-3}$ , 其对于 SoH 预测效果为 3 个电池中最佳。对于 CS2-36 电池, GRU、SVD-GRU、SVD-SSA-GRU 模型的 RMSE 分别为  $3.14 \times 10^{-2}$ 、 $2.53 \times 10^{-2}$  和  $1.84 \times 10^{-2}$ , SVD-SSA-GRU 比前者均有不同程度的减少。本研究所提模型对 CS2-37 电池的改善效果最为明显, SVD-SSA-GRU 模型的 RMSE 为  $1.36 \times 10^{-2}$ , 而 GRU 模型的 RMSE 为  $3.05 \times 10^{-2}$ , 其 RMSE 在 GRU 模型的基础上减少了 55.41%。总体上本研究所提模型对 3 个电池都能实现准确估

表 5 SoH 估计结果对比

Tab. 5 Comparison of SoH estimation results

电池	GRU			SVD-GRU			SVD-SSA-GRU		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
CS35	0.018 0	0.013 9	1.73%	0.011 5	0.008 9	1.10%	0.007 3	0.005 9	0.72%
CS36	0.031 4	0.025 0	3.21%	0.025 3	0.019 4	2.51%	0.018 4	0.013 7	1.76%
CS37	0.030 5	0.026 1	3.18%	0.019 9	0.016 3	1.98%	0.013 6	0.010 8	1.32%

计,其最大 RMSE 不超过  $1.84 \times 10^{-2}$ ,同时 SVD-SSA-GRU 模型对 SoH 的估计精度对比 SVD-GRU 和 GRU 模型,均有不同程度的提升。

#### 4 结论

本文提出一种基于奇异值定阶降噪和麻雀搜索算法优化 GRU 神经网络的电池 SoH 预测方法,使用先进生命周期工程中心的电池数据集验证所提方法的有效性。首先基于电池老化机理提出了 3 个特征指标分别为 CCCT、CVCT、ADV,并计算了特征指标与 SoH 的 Spearman 相关系数。然后应用奇异值分解技术进行数据降噪,并使用麻雀搜索算法进行 GRU 神经网络模型的参数优化。最后基于公开数据集验证了所提模型的有效性,并对比分析了不同模型对于 SoH 的估计效果,验证了本方法的优越性。未来的研究将关注模型的鲁棒性,使用先进的深度学习算法,进一步提高 SoH 的预测精度。

#### 参考文献:

- [1] LI P H, ZHANG Z J, XIONG Q Y, et al. State-of-health estimation and remaining useful life prediction for the lithium-ion battery based on a variant long short term memory neural network [J]. *Journal of power sources*, 2020, 459: 228069. DOI: [10.1016/j.jpowsour.2020.228069](https://doi.org/10.1016/j.jpowsour.2020.228069).
- [2] 叶楚天. 动力电池及充电基础设施技术发展对电动汽车能量补给方式的影响研究 [J]. *南方能源建设*, 2017, 4(2): 69-72. DOI: [10.16516/j.gedi.issn2095-8676.2017.02.011](https://doi.org/10.16516/j.gedi.issn2095-8676.2017.02.011).  
YE C T. Research on the influence of power battery and charging infrastructure technology on the energy supply mode of electric vehicles [J]. *Southern energy construction*, 2017, 4(2): 69-72. DOI: [10.16516/j.gedi.issn2095-8676.2017.02.011](https://doi.org/10.16516/j.gedi.issn2095-8676.2017.02.011).
- [3] ZHANG Y J, LIU Y J, WANG J, et al. State-of-health estimation for lithium-ion batteries by combining model-based incremental capacity analysis with support vector regression [J]. *Energy*, 2022, 239: 121986. DOI: [10.1016/j.energy.2021.121986](https://doi.org/10.1016/j.energy.2021.121986).
- [4] 胡轲. 大容量储能系统电池管理系统均衡技术研究 [J]. *南方能源建设*, 2018, 5(1): 40-44. DOI: [10.16516/j.gedi.issn2095-8676.2018.01.006](https://doi.org/10.16516/j.gedi.issn2095-8676.2018.01.006).  
HU K. Research on balancing technology of battery management system of high-capacity energy storage system [J]. *Southern energy construction*, 2018, 5(1): 40-44. DOI: [10.16516/j.gedi.issn2095-8676.2018.01.006](https://doi.org/10.16516/j.gedi.issn2095-8676.2018.01.006).
- [5] 樊亚翔, 肖飞, 许杰, 等. 基于充电电压片段和核岭回归的锂离子电池 SoH 估计 [J]. *中国电机工程学报*, 2021, 41(16): 5661-5669. DOI: [10.13334/j.0258-8013.pcsee.201805](https://doi.org/10.13334/j.0258-8013.pcsee.201805).  
FAN Y X, XIAO F, XU J, et al. State of health estimation of lithium-ion batteries based on the partial charging voltage segment and kernel ridge regression [J]. *Proceedings of the CSEE*, 2021, 41(16): 5661-5669. DOI: [10.13334/j.0258-8013.pcsee.201805](https://doi.org/10.13334/j.0258-8013.pcsee.201805).
- [6] ZRAIBI B, OKAR C, CHAOUI H, et al. Remaining useful life assessment for lithium-ion batteries using CNN-LSTM-DNN hybrid method [J]. *IEEE transactions on vehicular technology*, 2021, 70(5): 4252-4261. DOI: [10.1109/TVT.2021.3071622](https://doi.org/10.1109/TVT.2021.3071622).
- [7] LI Y, LIU K L, FOLEY A M, et al. Data-driven health estimation and lifetime prediction of lithium-ion batteries: a review [J]. *Renewable and sustainable energy reviews*, 2019, 113: 109254. DOI: [10.1016/j.rser.2019.109254](https://doi.org/10.1016/j.rser.2019.109254).
- [8] TIAN J P, XIONG R, SHEN W X, et al. State-of-charge estimation of LiFePO<sub>4</sub> batteries in electric vehicles: a deep-learning enabled approach [J]. *Applied energy*, 2021, 291(3): 116812. DOI: [10.1016/j.apenergy.2021.116812](https://doi.org/10.1016/j.apenergy.2021.116812).
- [9] ZHANG S Z, GUO X, DOU X X, et al. A rapid online calculation method for state of health of lithium-ion battery based on coulomb counting method and differential voltage analysis [J]. *Journal of power sources*, 2020, 479(11): 228740. DOI: [10.1016/j.jpowsour.2020.228740](https://doi.org/10.1016/j.jpowsour.2020.228740).
- [10] ZHANG Q C, LI X, ZHOU C, et al. State-of-health estimation of batteries in an energy storage system based on the actual operating parameters [J]. *Journal of power sources*, 2021, 506: 230162. DOI: [10.1016/j.jpowsour.2021.230162](https://doi.org/10.1016/j.jpowsour.2021.230162).
- [11] GUO P Y, CHENG Z, 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: 442-450. DOI: [10.1016/j.jpowsour.2018.11.072](https://doi.org/10.1016/j.jpowsour.2018.11.072).
- [12] SU L S, ZHANG J B, WANG C J, et al. Identifying main factors of capacity fading in lithium ion cells using orthogonal design of experiments [J]. *Applied energy*, 2016, 163: 201-210. DOI: [10.1016/j.apenergy.2015.11.014](https://doi.org/10.1016/j.apenergy.2015.11.014).
- [13] XIONG R, LI L L, YU Z R, et al. An electrochemical model based degradation state identification method of lithium-ion battery for all-climate electric vehicles application [J]. *Applied energy*, 2018, 219: 264-275. DOI: [10.1016/j.apenergy.2018.03.053](https://doi.org/10.1016/j.apenergy.2018.03.053).
- [14] XU W H, WANG S L, JIANG C, et al. A novel adaptive dual extended Kalman filtering algorithm for the Li - ion battery state of charge and state of health co - estimation [J]. *International journal of energy research*, 2021, 45(12): 14592-14602. DOI: [10.1002/er.6719](https://doi.org/10.1002/er.6719).
- [15] LIN C P, XU J, SHI M J, et al. Constant current charging time based fast state-of-health estimation for lithium-ion batteries [J]. *Energy*, 2022, 247: 123556. DOI: [10.1016/j.energy.2022.123556](https://doi.org/10.1016/j.energy.2022.123556).
- [16] LI X Y, YUAN C G, LI X H, et al. State of health estimation for Li-ion battery using incremental capacity analysis and Gaussian process regression [J]. *Energy*, 2020, 190: 116467. DOI: [10.1016/j.energy.2019.116467](https://doi.org/10.1016/j.energy.2019.116467).



- [17] ZHOU Y, DONG G Z, TAN Q Q, et al. State of health estimation for lithium-ion batteries using geometric impedance spectrum features and recurrent Gaussian process regression [J]. *Energy*, 2023, 262: 125514. DOI: [10.1016/j.energy.2022.125514](https://doi.org/10.1016/j.energy.2022.125514).
- [18] LI Q L, LI D Z, ZHAO K, et al. State of health estimation of lithium-ion battery based on improved ant lion optimization and support vector regression [J]. *Journal of energy storage*, 2022, 50: 104215. DOI: [10.1016/j.est.2022.104215](https://doi.org/10.1016/j.est.2022.104215).
- [19] YANG S J, ZHANG C P, JIANG J C, et al. Review on state-of-health of lithium-ion batteries: characterizations, estimations and applications [J]. *Journal of cleaner production*, 2021, 314: 128015. DOI: [10.1016/j.jclepro.2021.128015](https://doi.org/10.1016/j.jclepro.2021.128015).
- [20] TANG T, YUAN H M. The capacity prediction of Li-ion batteries based on a new feature extraction technique and an improved extreme learning machine algorithm [J]. *Journal of power sources*, 2021, 514: 230572. DOI: [10.1016/j.jpowsour.2021.230572](https://doi.org/10.1016/j.jpowsour.2021.230572).
- [21] TAN X J, LIU X X, WANG H Y, et al. Intelligent online health estimation for lithium-ion batteries based on a parallel attention network combining multivariate time series [J]. *Frontiers in energy research*, 2022, 10: 844985. DOI: [10.3389/fenrg.2022.844985](https://doi.org/10.3389/fenrg.2022.844985).
- [22] DENG Y W, YING H J, E J Q, et al. Feature parameter extraction and intelligent estimation of the state-of-health of lithium-ion batteries [J]. *Energy*, 2019, 176: 91-102. DOI: [10.1016/j.energy.2019.03.177](https://doi.org/10.1016/j.energy.2019.03.177).
- [23] WANG Z K, ZENG S K, GUO J B, et al. State of health estimation of lithium-ion batteries based on the constant voltage charging curve [J]. *Energy*, 2019, 167: 661-669. DOI: [10.1016/j.energy.2018.11.008](https://doi.org/10.1016/j.energy.2018.11.008).
- [24] 连强. 综合区间数Spearman秩相关系数及其应用 [J]. *重庆工商大学学报(自然科学版)*, 2020, 37(6): 71-75. DOI: [10.16055/j.issn.1672-058X.2020.0006.011](https://doi.org/10.16055/j.issn.1672-058X.2020.0006.011).  
LIAN Q. The synthetic spearman rank correlation coefficient of interval numbers and its application [J]. *Journal of Chongqing technology and business University (natural sciences edition)*, 2020, 37(6): 71-75. DOI: [10.16055/j.issn.1672-058X.2020.0006.011](https://doi.org/10.16055/j.issn.1672-058X.2020.0006.011).
- [25] 练继建, 李火坤, 张建伟. 基于奇异熵定阶降噪的水工结构振动模态ERA识别方法 [J]. *中国科学(E辑:技术科学)*, 2008, 38(9): 1398-1413.
- LIAN J J, LI H K, ZHANG J W. ERA recognition method for hydraulic structure vibration modes based on singular entropy order denoising [J]. *Scientia sinica (technologica)*, 2008, 38(9): 1398-1413.
- [26] KALMAN D. A singularly valuable decomposition: the SVD of a matrix [J]. *The college mathematics journal*, 1996, 27(1): 2-23. DOI: [10.1080/07468342.1996.11973744](https://doi.org/10.1080/07468342.1996.11973744).
- [27] 张一帆. 改进的动态三次指数平滑法火电厂发电量预测研究 [D]. 河北: 河北工程大学, 2020. DOI: [10.27104/d.cnki.ghbjy.2020.000298](https://doi.org/10.27104/d.cnki.ghbjy.2020.000298).  
ZHANG Y F. Research on forecast of power generation of thermal power plant base on dynamic three exponential smoothing [D]. Hebei: Hebei University of Engineering, 2020. DOI: [10.27104/d.cnki.ghbjy.2020.000298](https://doi.org/10.27104/d.cnki.ghbjy.2020.000298).
- [28] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [J]. *Eprint arxiv*, 2014. DOI: [10.48550/arXiv.1412.3555](https://doi.org/10.48550/arXiv.1412.3555).
- [29] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. *Systems science & control engineering an open access journal*, 2020, 8(1): 22-34. DOI: [10.1080/21642583.2019.1708830](https://doi.org/10.1080/21642583.2019.1708830).

---

作者简介:



王超

王超 (第一作者)

1976-, 工程师, 电力系统及其自动化专业硕士, 主要从事电网规划、投资管理、电价方面的研究工作 (e-mail) [13928831766@139.com](mailto:13928831766@139.com)。



黄广山

黄广山 (通信作者)

1998-, 硕士研究生在读, 主要从事智能电网、储能系统安全方面的研究工作 (e-mail) [1412028438@qq.com](mailto:1412028438@qq.com)。

(编辑 赵琪)