

基于混合健康因子和改进 BiGRU 神经网络的 锂电池 SOH 估计

陈将宏¹, 杨昊¹, 杨志淳², 闵怀东²

(1. 三峡大学 电气与新能源学院, 湖北 宜昌 443002;

2. 国网湖北省电力有限公司电力科学研究院, 湖北 武汉 430077)

摘要: 准确估计锂离子电池的健康状态(SOH)对提升其安全性与延长使用寿命具有重要意义。针对现有数据驱动方法在健康因子表征不充分及模型泛化能力不足的问题,提出一种基于混合健康因子与改进双向门控循环单元(BiGRU)神经网络的SOH估计方法。首先,通过融合充放电曲线特征与二阶等效电路模型参数,构建多维混合健康因子,实现对电池老化行为的全面刻画。随后,引入结合混沌初始化、非线性递减因子以及柯西-高斯混合变异的改进哈里斯鹰优化算法(IHHO),用于优化BiGRU超参数,并集成自注意力机制(SA),构建IHHO-BiGRU-SA模型。最后,基于CALCE与NASA电池数据集对所提模型进行验证。结果表明:IHHO-BiGRU-SA模型在CALCE数据集上的平均绝对误差(MAE)与均方根误差(RMSE)分别较传统方法平均降低46.0%和43.9%;在NASA数据集上分别平均降低39.3%和38.7%。实验结果验证了所提方法在SOH估计中的高精度与优异的泛化性能。

关键词: 锂离子电池;健康状态估计;改进双向门控循环单元;混合健康因子

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed27039

State of Health Estimation of Lithium-ion Batteries Based on Health Indicators and Improved BiGRU Neural Network

CHEN Jianghong¹, YANG Hao¹, YANG Zhichun², MIN Huaidong²

(1. School of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, Hubei, China; 2. Electric Power Research Institute of State Grid Hubei Co., Ltd., Wuhan 430077, Hubei, China)

Abstract: Accurate estimation of the state of health (SOH) of lithium-ion batteries is crucial for enhancing their safety and extending their service life. To address the limitations of existing data-driven methods in capturing health indicators and achieving sufficient model generalization, an SOH estimation method based on hybrid degradation features and an improved bidirectional gated recurrent unit (BiGRU) neural network was proposed. First, by integrating charge-discharge curve features with parameters of a second-order equivalent circuit model, a multidimensional hybrid health indicator was constructed to comprehensively characterize battery degradation behavior. Then, an improved Harris Hawks optimization (IHHO) algorithm combining chaotic initialization, nonlinear decreasing factor, and Cauchy-Gaussian hybrid mutation was employed to optimize the BiGRU hyperparameters. Meanwhile, a self-attention (SA) mechanism was incorporated to build the IHHO-BiGRU-SA model. Finally, the proposed model was validated using CALCE and NASA battery datasets. Experimental results show that compared with traditional methods, the proposed IHHO-BiGRU-SA model averagely reduces the mean absolute error (MAE) and root mean square error (RMSE) by 46.0% and 43.9% on the CALCE dataset, and by 39.3% and 38.7% on the NASA dataset, respectively. These results demonstrate that the proposed method achieves high estimation accuracy and excellent generalization performance in SOH estimation.

Key words: lithium-ion battery; state of health (SOH) estimation; improved bidirectional gated recurrent unit (BiGRU); hybrid health indicator

基金项目: 国家重点研发计划政府间国际科技创新合作项目(2024YFE0115600); 国网总部科技项目(52150025000Q)

作者简介: 陈将宏(1979—),男,博士,讲师,主要研究方向为电力系统可靠性分析与评估,Email: chenjh97@126.com

通讯作者: 杨昊(2001—),男,硕士研究生,主要研究方向为锂离子电池状态估计,Email: 15607240008@163.com

推动电动汽车的广泛应用是实现“双碳”目标的重要途径^[1]。而电池系统则是保障电动汽车安全与可靠运行的核心技术。锂离子电池凭借其高能量密度、高功率密度以及低自放电率等优势^[2-3],已成为电动汽车动力电池系统的首选。然而,在长期的充放电循环中,锂电池活性物质不可避免地减少,进而导致容量衰减和内阻增大,这一现象被称为电池老化。电池老化不仅削弱其充放电性能和功率输出^[4],若未能及时调整与老化相关的电池参数,如最大可用容量,还可能导致过充或过放,加速锂电池老化,进而严重威胁其安全性和降低使用寿命。因此,准确评估电池老化程度至关重要。在电池管理系统中,健康状态(state of health, SOH)作为衡量电池老化程度的关键指标^[5],其精确获取不仅对提升电池安全性至关重要,也能有效延长电池的使用寿命。

现有的锂电池SOH估计方法主要分为3类^[6]:实验方法、基于模型的方法和数据驱动的方法。其中,实验方法通常通过完整的充放电循环,并结合安时积分法来测定电池容量,从而获得较为准确的SOH估计结果。然而,该方法不仅耗时较长,而且依赖于特定的充放电条件,因而难以应用于实际的车载系统^[7]。基于模型的方法往往借助电化学模型或经验模型实现SOH估计,其中电化学模型利用锂电池机理知识描述老化轨迹和潜在的失效模式;而经验模型基于实验数据拟合获得模型参数。尽管基于模型的方法被广泛使用,但由于基于模型的方法依赖于模型参数的准确性,而模型参数会随电池运行条件而发生变化,因此影响SOH估计的精度^[8]。相比之下,基于数据驱动的方法无需深入理解电池老化机理,而是利用机器学习等算法从电池使用数据中学习和识别电池衰退的模式和趋势,从而实现电池SOH准确估计,解决了基于机理模型方法泛用性低的问题,因而被广泛应用于电池SOH估计^[9-11]。需要注意的是,基于数据驱动的SOH估计方法的准确性依赖于两个因素^[12]:一是健康因子(health indicator, HI),二是模型训练算法。

电池健康因子的选取是影响SOH估计的关键因素。现有的健康因子提取方法主要基于充电曲线或等效电路模型。一方面,由于放电过程具有较强的随机性,许多研究集中于充电过程的健康因子提取,常见方法包括提取恒流和恒压充电阶段的电流、时间、温度等物理量作为健康因

子^[8]。例如,文献[13]利用电流、电压和时间3个简单易测的参数作为健康因子;文献[14]利用电池恒流和恒压充电数据推导出容量增量曲线,并基于该曲线提取健康因子。此类基于充电曲线的健康因子能够直接且易于在线获取,但容易受到传感器噪声及工况波动的影响,稳定性不足。另一方面,也有研究基于等效电路模型提取健康因子。例如,文献[15]提出以电荷转移电阻为健康因子;文献[16]联合固体电解质界面电阻、电荷转移电阻、分数阶系数等模型参数作为健康因子。等效电路模型能够通过测量物理量来定量地辨识参数,从而定量揭示欧姆电阻、极化电阻及电容等参数随电池老化的变化过程。这种方法无需特定的充放电条件。然而,等效电路模型中的参数不仅受到电池老化的影响,还受到温度、荷电状态和倍率等因素的干扰^[17],其鲁棒性相对较弱。因此,单一的健康因子往往无法全面地反映电池的老化过程。综合利用充电曲线和等效电路模型的特征,能够从宏观与微观层面对电池老化进行双重表征,从而提升健康因子的有效性。

同样地,老化模型训练算法也是影响SOH估计精度的关键因素。人工神经网络及其变体网络被广泛应用于SOH估计模型的构建。例如,文献[18]提出了基于迁移学习与长短期记忆神经网络相结合的训练算法;文献[19]构建了融合深度置信网络、长短期记忆网络和挤压-激励机制的混合神经网络,该网络被用于电池容量估计。近年来,门控循环单元(gated recurrent unit, GRU)神经网络由于引入了双向循环结构,能够同时利用历史与未来信息,在保持较低计算复杂度的同时有效缓解了梯度消失问题,具备良好的长期依赖建模能力,广泛应用于电池状态估计。例如,文献[20]提出基于双向门控循环单元(bidirectional gated recurrent unit, BiGRU)神经网络构建荷电状态估计模型;文献[21]提出了基于迁移学习与门控循环单元神经网络的训练算法。值得注意的是,网络构建过程中的关键超参数显著影响训练模型精度。由于人工经验调节超参数效率低且难以实现最优配置,实现超参数的自动调节已成为提升训练算法精度的迫切问题。

综上所述,组合充放电曲线和等效电路模型的混合健康因子提取和改进能够优化神经网络超参数的BiGRU神经网络是提升SOH估计精度的有效途径。因此,本文提出了一种结合二阶等

效电路模型与充放电曲线特征的混合健康因子提取方法,并引入一种改进 Harris 鹰优化(improved Harris hawks optimization, IHHO)算法,该算法结合了混沌初始化、非线性递减因子和柯西-高斯混合变异机制,以优化 BiGRU 神经网络的超参数。最终,基于改进后的 BiGRU 神经网络构建了混合健康因子与 SOH 估计模型,以实现更为准确的 SOH 估计。

1 健康因子提取

1.1 电池数据集

本文选用的数据集来自美国马里兰大学先进生命周期工程中心(CALCE)和美国航空航天局(NASA)公开的锂离子电池老化数据集。为保证结果的代表性与模型的通用性,分别选取 CALCE 数据集中编号为 CS2_35, CS2_36, CS2_37 的电池,以及 NASA 数据集中编号为 B0005, B0006, B0007 的电池作为研究对象。

两类电池均在恒流恒压(CC-CV)模式下进行充、放电,充电电流分别设定为 1.1 A(CALCE)和 1.5 A(NASA),放电电流分别为 0.55 A 与 2 A。虽然工况参数略有差异,但两者的衰退趋势具有相似性,因此本文选用这两类数据集来验证模型在不同数据集上的适用性。

1.2 充放电曲线特征

在实际应用中,锂离子电池最常见的工作模式为恒流充放电。随着循环次数增加,电池的充放电曲线会发生显著变化。如图 1 所示,充电曲线随循环推进逐渐向左上方偏移,而放电曲线整体向左下方移动。这种变化主要源于电池在反复充放电过程中活性物质损耗、电极极化加剧及内部阻抗增加,使得有效容量逐步衰减,从而导致恒流充放电过程更早达到截止条件。

为了定量表征充放电曲线随循环的变化规律,本文从恒流工况下的充放电曲线中提取了 4 个健康因子,分别为:恒流充电时间(HI1)、恒压充电时间(HI2)、放电初始电压(HI3)以及放电平台电压(HI4)。这些特征参数能够在一定程度上反映电池的健康状态和衰退趋势。

此外,考虑到温度是影响电池老化过程的重要外部因素,为增强模型在复杂工况下的泛化能力与鲁棒性,本文在 NASA 数据集中进一步引入了两项温度相关健康因子:恒压充电阶段平均温升率(HI5)与充电阶段温度标准差(HI6)。前者




图1 CS2_35电池不同循环次数下的充放电曲线

Fig.1 Discharge and charge curves of CS2_35

battery at different cycle numbers

用于表征恒压阶段内部热积累速率,反映电池极化与副反应强度;后者用于衡量充电过程中温度波动程度,体现电池热稳定性变化。恒压充电阶段平均温升率的计算公式如下:

$$\frac{dT}{dt_{CV}} = \frac{T_{CV,end} - T_{CV,start}}{t_{CV,end} - t_{CV,start}} \quad (1)$$

式中: $T_{CV,end}$, $T_{CV,start}$ 分别为恒压充电阶段起始温度、结束时的温度; $t_{CV,end}$, $t_{CV,start}$ 分别为 $T_{CV,end}$, $T_{CV,start}$ 对应的时间点。

充电阶段温度标准差的计算公式如下:

$$\sigma_T = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (T_i - \bar{T})^2} \quad (2)$$

式中: T_i 为充电阶段第 i 个采样点的温度; $\bar{T}$ 为该阶段的平均温度; N 为温度采样点总数。

由于 CALCE 数据集未包含温度测量信息,上述两项温度特征仅适用于 NASA 数据集。引入关于温度的特征使得模型在具备温度观测条件下更好地捕捉热-电耦合老化特征,从而提升健康评估的物理一致性与预测精度。

1.3 二阶 RC 等效电路模型

在电池管理系统中,等效电路模型因其结构简单、计算效率高及物理意义明确,被广泛用于状态估计与系统控制。为在模型精度与计算复

杂度之间取得平衡,本文选用了二阶RC等效电路模型。该模型在传统一阶RC模型的基础上增加一个并联RC网络,以更准确地表征电池在动态充放电过程中的极化效应与滞后特性。

如图2所示,二阶RC等效电路模型包含4个主要部分:电压源 U_{ocv} ,用于描述电池的开路电压;欧姆内阻 R_0 ;用于反映电化学极化效应的电化学极化电阻 R_1 与电容 C_1 ;用于刻画浓差极化效应的浓差极化电阻 R_2 与电容 C_2 。 U_{c1} 和 U_{c2} 分别表示两个RC网络上的电容电压, I 表示电池的输出电流。




图2 二阶RC等效电路模型

Fig.2 Second-order RC equivalent circuit model

电池的输出端电压 U 可由下式表示:

$$U = U_{ocv} - IR_0 - U_{c1} - U_{c2} \quad (3)$$

其中

$$\frac{dU_{c1}}{dt} = \frac{U_{c1}}{R_1 C_1} + \frac{I}{C_1} \quad (4)$$

$$\frac{dU_{c2}}{dt} = \frac{U_{c2}}{R_2 C_2} + \frac{I}{C_2} \quad (5)$$

电池的开路电压 U_{ocv} 为SOC的非线性函数,通常采用多项式拟合,具体如下:

$$U_{ocv} = f(SOC) = \sum_{i=0}^M \alpha_i SOC^i \quad (6)$$

其中

$$SOC = SOC_0 - \frac{\int \eta I dt}{C_N} \quad (7)$$

式中: α_i 为拟合多项式的系数; SOC_0 为初始荷电状态; C_N 为电池最大可用容量; η 为充放电效率,通常取为1。

1.4 等效电路模型参数辨识

参数辨识是构建准确模型的关键步骤,本文采用递推最小二乘法(recursive least squares, RLS)辨识二阶RC模型参数,包括欧姆内阻 R_0 ,电阻 R_1 , R_2 以及电容 C_1 , C_2 ,RLS的核心思想是通过最小化观测值与模型预测值之间误差的平方和,以获得最优的参数估计结果。RLS方法能够在数据不断更新的过程中实时修正参数,实现模型参数的自适应估计,从而使模型输出与实际测量数据

的偏差尽可能减小。RLS算法具体如下:

$$\begin{cases} e(k) = y(k+1) - \boldsymbol{\varphi}^T(k+1) \hat{\boldsymbol{\theta}}(k) \\ \hat{\boldsymbol{\theta}}(k+1) = \hat{\boldsymbol{\theta}}(k) + \mathbf{K}(k+1) e(k) \\ \mathbf{K}(k+1) = \mathbf{P}(k) \boldsymbol{\varphi}(k+1) [1 + \boldsymbol{\varphi}^T(k+1) \mathbf{P}(k) \boldsymbol{\varphi}(k+1)]^{-1} \\ \mathbf{P}(k+1) = \mathbf{P}(k) - \mathbf{K}(k+1) \boldsymbol{\varphi}^T(k+1) \mathbf{P}(k) \end{cases} \quad (8)$$

式中: $\hat{\boldsymbol{\theta}}(k)$ 为第 k 步时的参数估计向量; $e(k)$ 为预测误差,是预测值与实际值之间的差值; $y(k+1)$ 为在 $k+1$ 步的实际观测值; $\boldsymbol{\varphi}(k+1)$ 为 $k+1$ 步时的输入向量(也称为回归向量),它包含了与输出相关的特征; $\mathbf{K}(k+1)$ 为第 $k+1$ 步的增益矩阵; $\mathbf{P}(k+1)$ 为第 $k+1$ 步的协方差矩阵。

RLS迭代辨识得到的参数结果如图3所示。由图3可见,随着循环次数的增加,欧姆内阻 R_0 、电化学极化电阻 R_1 及浓差极化电阻 R_2 均呈现逐渐上升的趋势。这主要是由于电池在长期充放电过程中,电极/电解液界面不可逆副反应持续发生,致使SEI膜不断增厚;同时,电极活性材料逐步脱落、导电剂发生劣化,集流体与电极界面的接触阻抗增大,进而引起整体内阻上升。此外,电化学极化电阻 R_1 与电荷转移速率降低有关,而浓差极化电阻 R_2 的增加还和离子扩散路径受阻




图3 CS2_35电池模型参数辨识结果

Fig.3 Identification results of model parameters for CS2_35 battery

有关,反映出电极反应动力学的衰退和浓差极化的加剧。与此同时,电化学极化电容 C_1 、浓差极化电容 C_2 随循环次数的增加呈现逐渐下降的趋势,这主要是由于电极有效比表面积减少、孔隙结构塌陷以及电极材料活性降低等因素导致的极化响应能力减弱。

综上所述,RC参数的变化规律与电池内部结构退化及界面阻抗增长密切相关,能够有效表征电池的健康状态与性能衰减过程。因此,本文将欧姆内阻 R_0 (HI7)、极化电阻 R_1 (HI8)和 R_2 (HI9)、极化电容 C_1 (HI10)和 C_2 (HI11)作为健康因子,用于后续电池健康状态估计。

1.5 相关系数分析

本文从充放电曲线中提取了6个健康特征(HI1~HI6),从ECM参数中提取了5个健康特征(HI7~HI11),其中CALCE数据集因未包含温度测量信息而不含HI5和HI6,其相关系数图如图4所示。




图4 各电池健康因子与SOH间的相关系数图

Fig.4 Correlation coefficients between battery health indicators and SOH

从图4中可以看出,大部分健康因子与SOH之间有较强的相关性,适合作为SOH估计算法的输入。其中来自充放电曲线的健康因子(HI1~HI6)的相关性略高于来自于ECM参数的健康因子(HI7~HI11),这是因为ECM参数表征的是电池的瞬态响应特性,对局部老化过程敏感但全局退化趋势捕捉能力有限,因此其相关系数

普遍低于直接从充放电曲线提取的健康因子。但ECM参数具有无需依赖特定工况即可提取的优势,因而在适用性和便利性方面具有明显优势。

2 基于IHHO-BiGRU-SA的健康状态估计模型

2.1 BiGRU神经网络

GRU具有更加简洁的结构,引入了更新门和重置门来解决传统RNN中梯度爆炸的问题。更新门和重置门分别表示为

$$z_t = \sigma(w_z \cdot [h_{t-1}, x_t]) \quad (9)$$

$$r_t = \sigma(w_r \cdot [h_{t-1}, x_t]) \quad (10)$$

式中: σ 为Sigmoid激活函数; w_z, w_r 为权重矩阵; h_{t-1} 为前一时刻的隐藏状态; x_t 为当前输入。

作为GRU的改进,BiGRU由两个独立的GRU层构成,其分别沿正向处理时间序列信息和沿反向处理时间序列信息。通过这种双向特性,能够有效地提升非线性回归预测的准确性和鲁棒性。BiGRU结构如图5所示。




图5 BiGRU神经网络结构图

Fig.5 Architecture of the BiGRU neural network

2.2 改进HHO算法

由于BiGRU神经网络的超参数对SOH估计的准确性有所影响,因此,建立了IHHO算法来寻找网络的最佳隐含层数量、正则化系数和学习率。哈里斯鹰优化(Harris hawks optimization, HHO)算法源于哈里斯鹰在捕猎过程中协同追踪猎物的群体行为,其主要包含种群初始化、探索阶段以及开发阶段3个部分,具体如下:

1)种群初始化,数学模型如下:

$$X_i^0(t) = rand \cdot (ub - lb) + lb \quad i = 1, 2, \dots, N \quad (11)$$

式中: X_i^0 为第 i 个初始个体; ub, lb 分别为搜索空间的上、下界; N 为种群数量; $rand$ 为0~1之间的

随机数。

2)探索阶段,数学模型如下:

$$X(t+1)=\begin{cases} X_{\text{rand}}(t)-\text{rand}|X_{\text{rand}}(t)-2\text{rand}|X(t) & q\geq 0.5 \\ [X_{\text{prey}}(t)-X_m(t)]-\text{rand}[lb+\text{rand}(ub-lb)] & q<0.5 \end{cases} \quad (12)$$

式中: $X(t)$, $X(t+1)$ 分别为鹰在当前和下一次迭代的位置; $X_{\text{prey}}(t)$ 为猎物位置; $X_{\text{rand}}(t)$ 为随机选取的种群个体位置; $X_m(t)$ 为鹰的平均位置。

3)开发阶段。在开发阶段,鹰会根据猎物的逃逸能量与当前状态,采用包含软围攻、硬围攻、渐进式快速俯冲的软围攻和渐进式快速俯冲的硬围攻4种策略之一进行攻击。

在开发阶段,HHO算法会依据逃逸能量选择不同的袭击策略,逃逸能量可表示为

$$E = 2E_0(1 - t/T) \quad (13)$$

式中: E_0 为初始能量,范围 $[-1, 1]$; t , T 分别为当前迭代次数与最大迭代次数。

参数 p 用于表示猎物逃脱成功或失败的概率, $|E|$ 用于确定是否发生软围攻和硬围攻。

①软围攻($p\geq 0.5$, $|E|\geq 0.5$)数学模型如下:

$$X(t+1) = \Delta X(t) - E|JX_{\text{prey}}(t) - X(t)| \quad (14)$$

其中

$$\Delta X(t) = X_{\text{prey}}(t) - X(t)$$

$$J = 2(1 - \text{rand})$$

式中: J 为猎物在逃跑过程中的跳跃行为。

②硬围攻($p\geq 0.5$, $|E|< 0.5$)数学模型如下:

$$X(t+1) = X_{\text{prey}}(t) - E|\Delta X(t)| \quad (15)$$

③渐进式快速俯冲的软围攻($p< 0.5$, $|E|\geq 0.5$)数学模型如下:

$$X(t+1) = \begin{cases} Y & F(Y) < F[X(t)] \\ Z & F(Z) < F[X(t)] \end{cases} \quad (16)$$

其中

$$Y = X_{\text{prey}}(t) - E|JX_{\text{prey}}(t) - X(t)|$$

$$Z = Y + S \cdot \text{Levy}(D)$$

式中: Y , Z 分别为种群接下来行动的函数与俯冲行为; D 为维度; S 为 $1 \times D$ 维的随机向量,其维度服从区间 $[0, 1]$ 上的均匀分布; Levy 为列维飞行函数。

④渐进式快速俯冲的硬围攻($p< 0.5$, $|E|< 0.5$)数学模型如下:

$$Y = X_{\text{prey}}(t) - E|JX_{\text{prey}}(t) - X_m(t)| \quad (17)$$

该策略中,鹰群的俯冲行为和下一步位置与渐进式快速俯冲的软围攻的方程一致。

然而,原始HHO算法仍需进一步改进,以避免算法陷入局部最优,平衡全局探索与局部开发。本文在种群初始化、逃逸能量和开发阶段进行了改进。

改进1:混沌映射初始化。由于HHO算法的初始种群是随机生成的,其在搜索空间中的分布可能较为集中,进而限制了算法对全局搜索空间的充分利用。为了增强种群多样性,引入了Circle混沌映射初始化策略,新的种群初始化表示为

$$X_{i+1} = \text{mod}[X_i + 0.2 - \frac{0.5}{2\pi} \sin(2\pi X_k), 1] \quad (18)$$

式中: mod 为求余函数; X_k 为Circle映射在第 k 次迭代时的值。

Circle映射分布在 $[0, 1]$ 之间。

改进2:非线性递减因子。在HHO中,能量因子的线性下降并不能准确反映复杂搜索过程。为了提升算法在前期的全局探索能力和在后期局部搜索的准确性,一种非线性递减的逃逸能量被用来建立平衡开发和利用行为,其方程为

$$E = \alpha \times \{0.5 \times [1 + \cos(\pi \frac{t}{T})^\beta]\} \quad (19)$$

式中: α , β 为控制系数。

改进3:柯西-高斯混合变异。为了增强HHO算法跳出局部最优的能力和全局搜索性能,本文提出柯西-高斯混合变异策略,其结合了柯西和高斯两种分布的特性。柯西密度函数和高斯密度函数分布被定义为

$$f_c(x) = 0.01 \times \tan[\pi(U_c - 0.5)] \quad (20)$$

$$f_g(x) = 0.05 \times N_g \quad (21)$$

式中: U_c , N_g 分别为均匀分布和标准正态分布。可以得到柯西和高斯的混合变异函数为

$$f_h(x) = 0.7 \cdot f_c(x) + 0.3 \cdot f_g(x) \quad (22)$$

通过引入混合分布算子,种群与猎物之间的距离会缩小,从而使整体步长快速收缩并更快达到最优适应度值。该策略在硬围攻阶段触发,其数学模型可描述如下:

$$X(t+1) = X_{\text{prey}}(t) - E|\Delta X(t)| \cdot f_h(x) \quad (23)$$

为了验证IHHO算法的有效性,选取了CEC2017中的F1和F2测试函数,并与HHO, HHO-e(线性递减因子)、HHO-cg(无柯西-高斯变异)和HHO-ini(随机初始化)对比。对比结果如图6所示。

IHHO在收敛速度和寻优精度上均优于HHO




图6 不同算法的性能对比

Fig.6 Performance comparison of different algorithms

及其变体。在迭代初期,IHHO下降最快,表明改进初始化策略有效提升了早期搜索效率。相比HHO-cg在F1中期陷入停滞,而IHHO能持续下降并收敛至最低适应度值,证实了柯西-高斯变异增强了算法跳出局部最优的能力。此外,IHHO在F2后期优于HHO-ini,说明混沌初始化提升了种群质量。综上,IHHO具有平衡全局探索与局部开发能力,验证了多策略改进的有效性。

2.3 自注意力机制

自注意力机制通过衡量序列中各元素之间的相关性权重,对输入特征进行加权重构,从而使模型能够建模长程依赖关系,并生成包含全局上下文信息的特征表示。

假设输入序列为 $S = [S_1, S_2, \dots, S_n]$,其中 S_i 为序列中的第 i 个元素。将 S_i 与不同的权重向量相乘得到:

$$\begin{cases} Q = S_i W_q \\ K = S_i W_k \\ V = S_i W_v \end{cases} \quad (24)$$

式中: Q, K, V 分别为查询向量、键向量和值向量; W_q, W_k, W_v 为权重矩阵; S_i 为第 i 个时间步的输入特征向量。

计算每个查询向量与所有键向量之间的注意力分数,如下所示:

$$S_c = Q \cdot K^T \quad (25)$$

式中: S_c 为第 i 个位置的查询与第 j 个位置的键的注意力分数。

对注意力分数进行缩放,并通过Softmax转换

为概率分布为

$$Att = \text{soft}(QK^T / \sqrt{d_k}) \quad (26)$$

式中: Att 为第 i 个位置对第 j 个位置的注意力权重矩阵,权重之和等于1; d_k 为查询向量和键向量的缩放维度。

将注意力权重矩阵 Att 与值向量 V 相乘,得到加权后的输出,每个位置的输出是所有位置值的加权和,权重由注意力矩阵决定。输出表达式为

$$Z = Att \cdot V \quad (27)$$

2.4 IHHO-BiGRU-SA模型

基于BiGRU神经网络、改进的HHO算法和自注意力机制,构建了IHHO-BiGRU-SA模型用于锂离子电池SOH估计。具体步骤如下:

1) 电池数据获取:从二阶等效电路模型(ECM)获取电池数据,同时引入NASA和CALCE两种公开锂离子电池数据集。

2) 健康特征提取:从ECM参数中提取5个健康特征,从CALCE充放电曲线中提取4个健康特征,从NASA数据集中提取包含温升和温差的6个特征。

3) 训练集和测试集划分:对于马里兰大学CS2电池,用37号电池作为训练集,35号和36号电池分别作为测试集;对于NASA的B0005, B0006和B0007电池,前120次循环作为训练集,后48次循环作为测试集。

4) 构建模型并估计:构建IHHO-BiGRU-SA模型,用于对不同条件下的电池SOH进行估计。

5) 性能评估:利用平均绝对误差以及均方根误差作为指标,对所构建模型的性能进行评估。

针对所提出的SOH估计模型,BiGRU的优化器是Adam,最大迭代为200,批大小为10。优化算法寻优的超参数为:学习率的范围在0.001至0.01之间;隐含层单元数介于100至300之间;正则化系数范围为0.0001至0.01。此外,IHHO算法的最大迭代为20,种群数量均设为10。

3 估计结果与分析

3.1 跨电池训练的SOH估计对比

为验证所提模型的有效性,分别采用IHHO-BiGRU-SA, BiGRU和BiLSTM进行了SOH估计结果对比。以马里兰大学CS2_37号电池作为训练集,CS2_35和CS2_36号电池分别作为测试集。估计结果如图7所示,其中,图7a为3种方法对

CS2_35号电池估计的SOH结果及其误差,图7b为CS2_36号电池的SOH估计结果及其误差。

从图7中可以得出,基于IHHO-BiGRU-SA的SOH估计曲线更贴近真实SOH值,而BiGRU和BiLSTM方法的估计曲线与真实值的偏差相对较大。这证明了所提模型在电池SOH估计方面具有的有效性,能够更准确地反映电池的SOH变化趋势。




图7 跨电池训练的SOH估计结果

Fig.7 SOH estimation results of cross-cell training

用平均绝对误差(mean absolute error, MAE)与均方根误差(root mean squared error, RMSE)作为指标来评估电池SOH估计的准确性,公式如下式:

$$MAE = \frac{1}{n} \sum_{i=1}^n |SOH_i - \widehat{SOH}_i| \quad (28)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SOH_i - \widehat{SOH}_i)^2}{n}} \quad (29)$$

式中: n 为数据个数; SOH_i , $\widehat{SOH}_i$ 分别为真实值和估计值。

不同电池通过不同方法的SOH估计的MAE和RMSE结果如表1所示。

对于CS2_35号电池SOH估计而言,IHHO-BiGRU-SA方法MAE为0.659%,精度最高,BiGRU和BiLSTM的MAE分别为1.06%,1.30%;CS2_36号电池估计结果与CS2_35号一致,IHHO-BiGRU-

SA方法MAE为0.575%,仍保持最高精度,凸显所提方法在不同电池SOH估计中的优越性。在RMSE指标上,IHHO-BiGRU-SA方法估计CS2_35号电池时,RMSE为0.805%,误差最小,结果最稳定,BiGRU(1.35%)和BiLSTM(1.57%)的SOH估计误差相对较高;估计CS2_36号电池时,所提方法RMSE为0.704%,同样展现出最佳准确性。上述结果验证了所提方法在电池SOH估计的优势。

表1 跨电池训练的SOH估计误差

Tab.1 Error in SOH estimation based on cross-battery training

电池	方法	MAE/%	RMSE/%
CS2_35	IHHO-BiGRU-SA	0.659	0.805
	BiGRU	1.06	1.35
	BiLSTM	1.30	1.57
CS2_36	IHHO-BiGRU-SA	0.575	0.704
	BiGRU	0.952	0.877
	BiLSTM	1.260	1.580

3.2 对同一电池划分数据集的SOH估计对比

为进一步验证所提方法的有效性和可靠性,运用IHHO-BiGRU-SA, BiGRU和BiLSTM3种方法对NASA的B0005, B0006和B0007电池进行SOH估计。每块电池的前120次循环用于模型训练,剩余循环用于测试,估计结果如图8所示。

相比其它方法,所提方法估计的SOH依然能够很好地跟踪实际SOH曲线。从表2所呈现的MAE和RMSE数据能够清晰看出,在3块电池的SOH估计中,基于IHHO-BiGRU-SA模型在各项指标上均展现出显著优势。所提方法在对B0005电池进行SOH估计的MAE为0.241%,RMSE为0.307%;在B0006电池上MAE为0.678%,RMSE为0.897%;在B0007电池上MAE为0.321%,RMSE为0.369%。相较于其他两种方法,IHHO-BiGRU-SA模型在估计SOH中依然保持了最高精度,这验证了所提方法在不同电池上的适用性和可靠性。

表2 同一电池划分数据集的SOH误差

Tab.2 SOH estimation error based on data partitioning from single

电池	方法	MAE/%	RMSE/%
B0005	IHHO-BiGRU-SA	0.241	0.307
	BiGRU	0.410	0.535
	BiLSTM	0.682	0.798
B0006	IHHO-BiGRU-SA	0.678	0.897
	BiGRU	0.955	1.267
	BiLSTM	1.065	1.434
B0007	IHHO-BiGRU-SA	0.321	0.369
	BiGRU	0.414	0.456
	BiLSTM	0.559	0.646




图8 同一电池划分数据的SOH估计结果

Fig.8 SOH estimation results based on data partitioning from single battery

3.3 考虑温度特征的SOH估计对比

本小节在之前的基础上,引入了温度作为健康特征,并在SOH估计时将改进算法与未改进算法进行了对比,估计结果如图9所示。表3为考虑温度特征的SOH估计误差,所提出的IHHO-BiGRU-SA模型在所有NASA电池上均取得了最优性能。在表现最好的B0007电池上,该模型的MAE和RMSE分别为0.229%和0.291%,误差低于未改进模型。即使在波动较大的B0006电池上,IHHO依然保持MAE为0.771%和RMSE为0.927%的优势。

此外,表4展示了两种算法的最佳超参数组合。其中,IHHO能够更精细地平衡模型的初始学习率和正则化系数。因此,IHHO具有更强的

寻优能力,能够找到更适合BiGRU网络的超参数,从而显著降低预测误差。并且,在模型引入温度特征后,SOH估计结果依然稳定。

以上结果证明了IHHO算法在提升模型泛化能力和鲁棒性方面的有效性。




图9 考虑温度特征的SOH估计结果

Fig.9 SOH estimation results considering temperature features

表3 考虑温度特征的SOH估计误差

Tab.3 SOH estimation error considering temperature features

电池	方法	MAE/%	RMSE/%
B0005	IHHO-BiGRU-SA	0.258	0.335
	HHO-BiGRU-SA	0.308	0.425
B0006	IHHO-BiGRU-SA	0.771	0.927
	HHO-BiGRU-SA	0.823	1.092
B0007	IHHO-BiGRU-SA	0.229	0.291
	HHO-BiGRU-SA	0.287	0.390

表4 最优超参数

Tab.4 Optimal hyperparameters

电池	算法	隐含层数	学习率	正则化系数
B0005	IHHO	300	0.01	1.295e-05
	HHO	187	0.001 7	1.107e-03
B0006	IHHO	156	0.004 9	1.559e-05
	HHO	300	0.003 8	1.791e-05
B0007	IHHO	271	0.009 1	1e-05
	HHO	227	0.004 1	3.518 9e-3

4 结论

本文提出一种基于混合老化特征与改进BiGRU神经网络的锂电池健康状态估计方法。通过融合充放电曲中的恒流/恒压充电时间、放电平台电压等特征以及二阶等效电路模型辨识得到的欧姆内阻与极化电阻等参数,构建多维健康因子,实现对电池老化过程的全面表征。基于原始HHO算法,加入混沌初始化、非线性能量衰减和柯西-高斯混合变异机制,从而增强其全局搜索性能并提高收敛稳定性,并用于优化BiGRU网络的超参数。同时,结合自注意力机制,提升模型对关键时序特征的捕捉能力,从而构建IHHO-BiGRU-SA模型。

实验结果表明,所提方法在CALCE与NASA公开数据集上均表现出优异性能。在跨电池训练与单电池划分场景下,CS2_35和CS2_36的SOH估计MAE分别为0.659%和0.575%,B0005、B0006和B0007的MAE分别为0.241%、0.678%和0.321%,显著优于对比的传统模型。该方法具有高精度、强鲁棒性及良好的泛化能力,为电池管理系统中SOH的在线精确估计提供了一条有效技术路径。未来的研究将进一步结合锂电池的电化学阻抗谱特征提取健康因子,并探索基于元学习的策略以提高本文在不同工况下的SOH估计精度。

参考文献

- [1] 董明,范文杰,刘王泽宇,等. 基于特征频率阻抗的锂离子电池健康状态评估[J]. 中国电机工程学报, 2022, 42(24): 9094-9105.
Dong Ming, Fan Wenjie, Liu Wangzeyu, et al. Health assessment of lithium-ion batteries based on characteristic frequency impedance[J]. Proceedings of the CSEE, 2022, 42(24): 9094-9105.
- [2] 单恩泽,王鹿军. 基于双阈值的高精度锂电池主被动均衡策略[J]. 电气传动, 2021, 51(11): 40-47.
Shan Enze, Wang Lujun. Active and passive equalization strategy of lithium battery based on high precision double threshold control[J]. Electric Drive, 2021, 51(11): 40-47.
- [3] 范元亮,朱俊伟,吴涵,等. 基于两阶段充电数据融合的储能系统锂离子电池SOH估计方法[J]. 电气传动, 2025, 55(3): 72-80.
Fan Yuanliang, Zhu Junwei, Wu Han, et al. State of health estimation method for lithium-ion batteries in energy storage systems based on two-stage charging data[J]. Electric Drive, 2025, 55(3): 72-80.
- [4] 黄佳茵,白俊琦,贤燕华. 基于DOD-LN-GPR模型的锂离子电池SOH估计方法[J]. 太阳能学报, 2025, 46(2): 60-69.
Huang Jiayin, Bai Junqi, Xian Yanhua. SOH estimation method of lithium-ion batteries based on DOD-LN-GPR model[J]. Acta Energiae Solaris Sinica, 2025, 46(2): 60-69.
- [5] 张子恒,耿萌萌,范茂松,等. 基于弛豫时间分布法的退役动力电池健康状态评估[J]. 储能科学与技术, 2025, 14(2): 770-778.
Zhang Ziheng, Geng Mengmeng, Fan Maosong, et al. SOH estimation based on distribution of relaxation times for the retired power lithium-ion battery[J]. Energy Storage Science and Technology, 2025, 14(2): 770-778.
- [6] Xiong Rui, Li Linlin, Tian Jinpeng. Towards a smarter battery management system: a critical review on battery state of health monitoring methods[J]. Journal of Power Sources, 2018, 405: 18-29.
- [7] Fu Yumeng, Xu Jun, Mei Xuesong, et al. A fast impedance calculation-based battery state-of-health estimation method[J]. IEEE Transactions on Industrial Electronics, 2021, 69(7): 7019-7028.
- [8] Tang Jinrui, Li Yang, Wang Shaojin, et al. Data-driven state of health estimation method of lithium-ion batteries for partial charging curves[J]. IEEE Transactions on Energy Conversion, 2024, 39(4): 2230-2243.
- [9] Yan Qin, Arunan Anushiya, Yuen Chuan. Digital twin for real-time Li-ion battery state of health estimation with partially discharged cycling data[J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 7247-7257.
- [10] Mao Ling, Wen Jialin, Zhao Jinbin, et al. Online state-of-health estimation of lithium-ion batteries based on a novel equal voltage range sampling count number health indicator[J]. IEEE Transactions on Transportation Electrification, 2023, 10(1): 2277-2292.
- [11] Dou Bowen, Hou Shujuan, Li Hai, et al. Short term charging data based battery state of health and state of charge estimation using feature pyramid[J]. IEEE Transactions on Vehicular Technology, 2023, 73(5): 6383-6394.
- [12] 巫春玲,王立顶,卢勇,等. 基于白鹭群优化高斯过程回归的锂电池SOH估计方法[J]. 储能科学与技术, 2025, 14(6): 2498-2511.
Wu Chunling, Wang Liding, Lu Yong, et al. Lithium-ion batteries SOH estimation based on Gaussian processed regression optimized by egret swarm optimization[J]. Energy Storage Science and Technology, 2025, 14(6): 2498-2511.
- [13] 孙静,翟千淳. 基于融合特征和OOA-BiGRU的锂离子电池剩余使用寿命预测方法[J]. 电工技术学报, 2025, 40(9): 2996-3012.
Sun Jing, Zhai Qianchun. A novel remaining useful life prediction method based on fusion feature and OOA-BiGRU for lithium-ion batteries[J]. Transactions of the China Electrotechnical Society, 2025, 40(9): 2996-3012.

- [14] Wei Zhongbao, Ruan Haikai, Li Yang, et al. Multistage state of health estimation of lithium-ion battery with high tolerance to heavily partial charging[J]. IEEE Transactions on Power Electronics, 2022, 37(6): 7432-7442.
- [15] Zhang Qunming, Huang Chengeng, Li He, et al. Electrochemical impedance spectroscopy based state-of-health estimation for lithium-ion battery considering temperature and state-of-charge effect[J]. IEEE Transactions on Transportation Electrification, 2022, 8(4): 4633-4645.
- [16] Lin Mingqiang, Hu Dingcai, Meng Jinhao, et al. Transfer learning-based lithium-ion battery state of health estimation with electrochemical impedance spectroscopy[J]. IEEE Transactions on Transportation Electrification, 2025, 11(3): 7910-7920.
- [17] 赵转, 曹以龙, 杜君莉, 等. 遗忘因子递推最小二乘法辨识锂离子电池参数[J]. 电池, 2023, 53(6): 629-633.
- Zhao Zhuan, Cao Yilong, Du Junli, et al. Identification of Li-ion battery parameters by forgetting factor recursive least square method[J]. Battery Bimonthly, 2023, 53(6): 629-633.
- [18] Shu Xin, Shen Jianwei, Li Guang, et al. A flexible state-of-health prediction scheme for lithium-ion battery packs with long short-term memory network and transfer learning[J]. IEEE Transactions on Transportation Electrification, 2021, 7(4): 2238-2248.
- [19] 徐志成, 杨达, 张闯, 等. 基于极化衰减特征与通道关注混合神经网络的锂离子电池容量在线估计[J]. 电工技术学报, 2025, 40(17): 5683-5702.
- Xu Zhicheng, Yang Da, Zhang Chuang, et al. Online estimation of lithium-ion battery capacity based on polarization decay feature and hybrid neural network with channel attention[J]. Transactions of the China Electrotechnical Society, 2025, 40(17): 5683-5702.
- [20] 柳博, 吴松荣, 付聪, 等. 基于改进白鲸算法优化BiTCN-BiGRU的锂电池SOC估计[J]. 电子测量技术, 2025, 48(9): 75-83.
- Liu Bo, Wu Songrong, Fu Cong, et al. SOC estimation of lithium batteries based on BiTCN-BiGRU optimized by improved beluga whale algorithm[J]. Electronic Measurement Technology, 2025, 48(9): 75-83.
- [21] 莫易敏, 余自豪, 叶鹏, 等. 基于迁移学习与GRU神经网络结合的锂电池SOH估计[J]. 太阳能学报, 2024, 45(3): 233-239.
- Mo Yiling, Yu Zihao, Ye Peng, et al. Lithium battery SOH estimation method based on combination of transfer learning and GRU neural network[J]. Acta Energetica Solaris Sinica, 2024, 45(3): 233-239.

收稿日期:2025-10-15

修改稿日期:2025-11-12