

基于 BMAFMO-SVR 的锂离子电池健康状态估计

刘 建,邢丽坤

安徽理工大学 电气与信息工程学院,安徽 淮南 232001

摘 要:目的 锂离子电池健康状态(SOH)估计已经成为研究的焦点,准确的 SOH 估计对于电动汽车的平稳运行和锂电池的保养至关重要;然而,锂离子电池的复杂工作原理以及其强烈的非线性和时变性使得 SOH 的准确估算具有挑战性。同时,电池运行环境和条件的多样性进一步增加了锂离子电池健康状态下降的不确定性。**方法** 提出了一种新的锂离子电池 SOH 估计方法,采用基于二进制多目标自适应鱼群洄游优化算法-支持向量回归(BMAFMO-SVR)的方法来估计锂电池的 SOH。该方法从绝对值微分热伏安法和绝对值微分热容量法的曲线中提取极值点作为健康特征,使用二进制多目标自适应鱼群洄游优化算法优化支持向量回归的核函数参数,最终通过优化后的支持向量回归对 SOH 进行精确估计,利用 NASA 数据集中 4 组电池进行对比试验。**结果** 结果表明:BMAFMO-SVR 在估计 SOH 方面具有较高的精度,RMSE 保持在 1%以内。**结论** 此方法有效地验证了其在提高锂电池健康状态预测精度的优越性和可行性。

关键词:锂离子电池;健康状态;绝对值微分热伏安;绝对值微分热容量;BMAFMO

中图分类号:TM912;TP18 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0004.019

State of Health Estimation of Lithium-ion Batteries Based on BMAFMO-SVR

LIU Jian, XING Likun

School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, Anhui, China

Abstract: Objective The estimation of the state of health (SOH) of lithium-ion power batteries has become a research focus. Accurate SOH estimation is crucial for the smooth operation of electric vehicles and the maintenance of lithium batteries. However, the complex working principles of lithium-ion power batteries, along with their strong nonlinearity and time-varying characteristics, make the accurate estimation of SOH challenging. Meanwhile, the diversity of battery operating environments and conditions further increases the uncertainty in the SOH degradation of lithium-ion power batteries. **Methods** A new method for estimating the SOH of lithium-ion power batteries was proposed. The binary multi-objective adaptive fish migration optimization algorithm-support vector regression (BMAFMO-SVR) was used to estimate the SOH of lithium batteries. This method extracted extreme points as health features from the curves of the absolute differential thermal voltammetry method and the absolute differential heat capacity method. The binary multi-objective adaptive fish migration optimization algorithm was used to optimize the kernel function parameters of support vector regression, and finally, the optimized support vector regression was used to accurately estimate the SOH. Comparative experiments were conducted on four groups of batteries from the NASA dataset. **Results** BMAFMO-SVR exhibited high

收稿日期:2024-05-28 **修回日期:**2024-07-29 **文章编号:**1672-058X(2026)04-0142-08

基金项目:安徽省高校自然科学基金重点项目(KJ2019A0106);淮南市 2021 年重点研究与开发计划项目资助(2021A249)。

作者简介:刘建(2000—),男,硕士生,安徽马鞍山人,从事电池管理系统研究。

通信作者:邢丽坤(1978—),女,硕士,副教授,安徽淮南人,从事智能信息采集与处理研究。Email:1355838110@qq.com。

引用格式:刘建,邢丽坤.基于 BMAFMO-SVR 的锂离子电池健康状态估计[J].重庆工商大学学报(自然科学版),2026,43(4):142-149.

Liu Jian, Xing Likun. State of health estimation of lithium-ion batteries based on BMAFMO-SVR[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(4): 142-149.

accuracy in SOH estimation, with the root mean square error (RMSE) within 1%. **Conclusion** This method demonstrates superiority and feasibility in improving the prediction accuracy of the state of health of lithium batteries.

Keywords: lithium-ion battery; state of health; absolute differential thermal voltammetry; absolute differential heat capacity; BMAFMO

由于石油危机和严重的污染,以汽油为燃料的汽车并未走上可持续发展的道路。此外,随着绿色、高效能和低碳增长理念的普及,电动汽车已经开始进入公众视野^[1-2]。锂离子电池作为电动汽车能量转换、存储和管理过程中的重要组成部分,其与铅酸、镍铬、镍氢等常用电池相比,具有比能量高、功率密度高、循环寿命长等优势^[3]。然而随着充放电循环次数的增加,锂离子电池的健康状态(SOH)逐渐下降。在电池退化过程中,正极材料溶解释放锂离子,负极材料逐渐氧化^[4],这些原因会导致电池容量降低,严重影响荷电状态(SOC)的准确性^[5]。内部化学反应速率降低,内阻增大,导致电池的最大放电功率和可用能量降低,能量状态(SOE)和功率状态(SOP)也受到影响^[6-7]。更严重的是,电池退化会伴随着高温高湿的变化,电池的安全状态(SOS)也会发生变化,引发安全事故。因此,需要准确地获得 SOH 参数,以维持电池的稳定运行,防止安全事故发生^[8-9]。

国内外对锂离子电池健康状态估计方法主要分为基于模型的方法和基于数据驱动的方法。传统的基于物理模型的 SOH(State of Health)估计方法通常依赖于对电池内部物理过程的复杂建模。然而,这些方法常常需要准确的参数化和理论假设,这些限制了它们在实际应用中的灵活性和适用性。相比之下,近年来基于数据驱动的 SOH 估计方法因其直接利用大量实际操作数据而备受关注。这些方法利用机器学习和统计分析技术,能够从丰富的操作数据中提取模式和趋势,以实现更精准和实时的 SOH 预测。数据驱动的方法不仅在实践中更易部署和调整,还能够有效地捕捉电池在不同工作条件下的复杂行为。因此,它们提高了预测的准确性和可靠性,为电池管理系统的实施带来了显著的优势。

随着机器学习的不断发展,基于数据驱动的方法在估计 SOH(State of Health)方面越来越受到欢迎。这种方法无需依赖电池退化模型,仅需分析电池的退化数据,并从中提取适当的健康特征进行模型训练。通过这一过程,能够获得高度准确的 SOH 预测^[10-12]。在 Li 等^[13]的研究中,通过分析 NASA 数据集,从充电/放电曲线中提取了 4 个健康特征,并将这些特征与改进的 Antlion 方法结合使用,用于 SOH 的估计。然而,值得注意的是,从恒压(CV)模式中提取的特征显示出与 SOH 的负相关性,因此在使用这些特征作为输入之前,

需要进行适当的处理。Deng 等^[14]采用 GRA 评估了健康特征与 SOH 之间的相关性,然后选择了最合适的特征。通过分析电池的容量增量(IC)曲线,获得了多个关键特征。在 Wen 等^[15]的研究中,提出了一种 BP 神经网络,能够有效地预测电池在各种温度下的 SOH。值得注意的是,对于数据驱动的 SOH 估计方法,首先,必须合理选择健康特征,以确保其能够充分反映电池的退化情况;其次,需要适当设置超参数,以避免模型过拟合,从而提高预测精度^[16]。

微分热伏安法(DTV)^[17-18]被提出以反映电极热力学响应的变化模式。鉴于蓄电池的充放电过程涉及复杂的热力学耦合反应, Lin 等^[19]引入了微分热容量法(DTC),以有效地揭示电化学和热力学特性。之后, Deng 等^[20]提出了一个被称为电荷量之差的标准差健康指标,并将其推广至一般工作条件。机器学习方法,如高斯过程回归、神经网络和支持向量回归(SVR)通常用于对输入特征和 SOH 之间的非线性映射建模。利用数据驱动方法的灵活性,能够通过测量数据中包含的热电特性来捕获当前电池老化的状态。在此利用 NASA 数据集,改良 Lin 等的特征曲线(DTC),从|DTV|和|DTC|的特征曲线中提取 4 个健康因子,能更有效地揭示电化学和热力学特性。采用 Pearson 系数评估健康特征与 SOH 之间的相关性。同时,提出以 RMSE 为适应度函数的 BMAFMO 算法^[21-22]搜索支持向量回归(SVR)模型的最优参数,此方法与 Wen 等^[15]的 BP 神经网络相比能更好地寻优以提高 SVR 的预测精度。通过这种方法,能够更准确地评估电池的状态与老化程度。

1 算法与模型

1.1 BMAFMO

2020 年, Chai 等提出了自适应鱼群洄游优化算法(AFMO),在鱼群洄游优化算法(FMO)中加入了自适应策略,避免鱼群在优化过程中陷入局部最优。当前候选解与最佳候选解之间的关系将影响鱼的游动方向。以下等式给予特定的鱼位置和速度更新等式:

$$V_i^{t+1} = w \cdot (p_{best}^t - p_i^t) \cdot \frac{e_i^t}{E_{max}} + \frac{fv_i - \bar{fv}_r}{|fv_i - \bar{fv}_r|} \cdot c \cdot \text{rand}() \cdot (p_i^t - p_i^t) \quad (1)$$

$$p_i^{t+1} = p_i^t + V_i^{t+1} \quad (2)$$

式(1)表示鱼群速度的更新方程,其中 w 表示权重因

子,权重因子决定了鱼是处于探索阶段还是开发阶段,深刻影响着鱼群中个体的搜索范围,随着迭代次数的变化, w 从 2 减小到 0.4。 p_i^t 表示第 t 代个体, p_{best}^t 表示第 t 代最优个体。 p_r^t 表示第 t 代的随机个体。 E_{max} 表示预定的最大能量值。 e_i^t 表示第 t 代中 i 个体的能量值。 fv_i 代表第 i 个个体的适应度值, fv_r 表示随机选择个体的适应度值。 c 是一个常数, $\text{rand}()$ 是 0~1 之间的随机数。在进化过程中,如果个体移动到新的位置后没有得到更好的候选解,则必须更新能量值。式(2)表示鱼群位置的更新方程。

二进制多目标自适应鱼群洄游优化算法(BMAFMO)是由 Zheng, Xu, Pan, Chai 于 2023 年提出,该算法应用存储库策略和拥挤度选择策略来提高全局搜索能力,并使用 Sigmoid 转换函数将连续解转换为二进制解。二进制多目标优化算法与普通多目标优化算法相似之处在于它们产生非支配解并且具有支配关系。如果 A 和 B 是通过多目标算法获得的两个解,则当满足以下公式时,可以说 A 优于 B 。

$$[(\forall i) B_i \leq A_i] \wedge [(\exists j) B_j < A_j] \quad (3)$$

利用知识库策略,可以存储生成的非支配解,以便在下次迭代中进行比较,从而避免了群体中优秀个体的损失。存储库策略的存储和删除方式如表 1 所示。

表 1 存储库策略的存储和删除方式

Table 1 Storage and deletion methods of repository policies

算法	BMAFMO
初始化鱼群	
while 最大迭代次数 do	
for 每个粒子 do	
通过式(4)更新当前粒子的速度	
通过式(5)将速度值映射到概率值	
If $r < s$ then	
$p = 1$;	
else	
$p = 0$	
end if	
end for	
if 任何新的解都位于超立方体之外	
then	
更新网格以覆盖新解决方案	
end if	
if 一个可支配的 pbest then	
更新能源消耗	
更新生长阶段	
end if	
到达第四阶段的粒子被初始化	
更新存储库	
if 存储库已满 then	
运行网格机制并更新存储库	
end if	
end while	

$$V_i^{t+1} = w \cdot (p_{\text{best}}^t - p_i^t) \cdot \frac{e_i^t}{E_{\text{max}}} + \frac{\sum (fv_i - fv_r)}{\left| \sum (fv_i - fv_r) \right|} \cdot c \cdot \text{rand}() \cdot (p_r^t - p_i^t) \quad (4)$$

$$s = \frac{1}{1 + e^{-v}} \quad (5)$$

式(5)中, v 代表个体的速度

1.2 支持向量回归(SVR)

SVR 是一种人工智能技术,该方法采用结构风险最小化理论,通过非线性映射将输入空间映射到高维空间。随后,在特征空间中解决线性回归问题,并构造回归估计函数。通过利用核函数,可以在原始输入空间中的非线性回归问题,并在高维特征空间中被重构为线性回归问题。SVR 是一种常见的机器学习模型,其原理在此就不再赘述,给出 SVR 模型训练的 3 个关键组成部分:

(1) 选择合适的内核函数。核函数的选择直接影响模型的表达能力和泛化能力。

(2) 优化核函数参数。这些参数决定了核函数的形式及其决策边界的复杂性。

(3) 确定参数 C 和 ε ,这两个参数决定了模型的拟合精度。

1.3 BMAFMO-SVR 模型

为了使支持向量回归具有最佳的泛化能力和预测精度,需要找到最佳的参数。在 SOH 估计中,利用正确的 C 和 σ ,可以使估计值尽可能接近真实的 SOH。在此使用 BMAFMO 优化算法来找到 SVR 模型中的最优参数。对 (C, σ) 进行编码,使得它们在 BMAFMO 中变得独立,然后构造合适的适应度函数,使个体值在训练过程中逐渐收敛到最优值,并找到最优参数,使模型性能最优。BMAFMO-SVR 的流程图如图 1 所示。




图 1 SOH 估计流程图

Fig. 1 Flowchart of SOH estimation

BMAFMO-SVR 主要步骤如下:

(1) 数据预处理。对样本数据进行归一化处理,

使预处理后的数据限制在一定范围内,消除异常特征的影响,将每个数据以相同的数量级放置。之后将数据分为训练集和测试集。

(2) SVR 参数设置。SVR 参数设置包括个体的维度 Dim 、最大迭代次数 T 、个体值的上限 UB 和个体值的下限 LB 以及种群数量 $iter_{max}$ 。

(3) 定义适应度函数。定义两个参数 (C, σ) 作为 BMAFMO 算法的个体,在训练过程中,每个个体都将在 SVR 中得到验证。提出了均方根误差 (RMSE) 作为适应度函数,并通过最小均方误差原则选择最优个体,公式如下:

$$R_{RMSE} = \sqrt{\frac{1}{n} \sum_i^n (\hat{y}_i - y_i)^2} \quad (6)$$

式(6)中, $\hat{y}_i$ 是测试样本的预测值, y_i 是测试样本的实际值, n 是测试样本的数量。

2 健康特征的实验与分析

2.1 SOH 定义

SOH 是电池管理系统 (BMS) 中的一个重要参数,它表示电池储存和释放容量的能力。了解电池的 SOH 对于电池的维护和管理非常重要,其定义如下:

$$S_{SOH} = \frac{C_i}{C_o} \times 100\% \quad (7)$$

其中, C_i 表示第 i 个电池的容量, C_o 表示电池的标称容量。

2.2 电池实验

本文数据来自 NASA 电池数据集。选用 2 Ah 的 B0005、B0006、B0007、B0018 电池进行研究,充电过程采用恒流恒压方式,放电过程以 2 A 的恒定电流来放电。电池实验信息如表 2 所示。

表 2 电池实验信息

Table 2 Battery experiment information

数据来源	电池类型	电池编号	温度/℃	放电电流/A	循环次数
NASA 实验数据	18650 型 锂电池	B0005	24	2	168
		B0006	24	2	168
		B0007	24	2	168
		B0018	24	2	131

实验处于常温环境,使用了 4 个锂电池 (标记为 B0005、B0006、B0007 和 B0018),并采用了 3 种不同的方式进行实验操作:充电、放电和阻抗测试。在充电阶段,以 1.5 A 的恒定电流模式进行,直到电池电压达到 4.2 V,然后切换到恒压模式,直到充电电流下降至 20 mA。放电过程采用了 2 A 的恒定电流水平,直到电池电压分别降至 2.7 V、2.5 V、2.2 V 和 2.5 V。使用电化学阻抗谱 (EIS) 进行频率扫描,范围从 0.1 Hz ~ 5 kHz,以测量电池的阻抗变化。通过反复进行充放电

循环,观察到电池老化的加速情况,而阻抗测量则能够深入了解内部电池参数随时间变化的情况。当电池达到寿命终止 (EOL) 标准时,实验停止,即电池额定容量衰减 30% (从 2 Ah ~ 1.4 Ah)。图 2 展示了 B0005、B0006、B0007 和 B0018 电池的退化曲线。




图 2 电池退化曲线

Fig. 2 Battery degradation curves

2.3 健康因子提取

健康因子能显著反映电池局部动态充电特性,如反映电化学特性反映热熵的 DTV 特征和反映热电耦合特性的 DTC 特征对电池进行老化描述。

考虑温度对电池老化的影响,DTV 定义如下:

$$D_{DTV} = \frac{dT}{dV} \quad (8)$$

考虑热电耦合效应,DTC 定义如下:



$$D_{DTC} = \frac{dT}{dQ} \quad (9)$$

而在实际实验过程中因为电池在放电的途中会因测量的误差或复杂的环境,导致数据会有许多波动,这使得上述两个特征曲线会因数据之间差值的正负号问题而变得断断续续,这使得后续的预测变得很有局限性。而在尝试一些数学变换后,发现 $|DTC|$ 和 $|DTV|$ 呈现出了良好的特征曲线,提取其健康因子并作为输入数据之后 SVR 模型可以实现 SOH 预测。

$$|D|_{|DTV|} = \left| \frac{dT}{dV} \right| \quad (10)$$

$$|D|_{|DTC|} = \left| \frac{dT}{dQ} \right| \quad (11)$$

以 B0005 电池为例,提取的健康特征如图 3、图 4 所示。如图 3、图 4 所示,3.6 ~ 3.9 V 之间曲线存在明显的波峰和波谷,随着电池循环次数的增加曲线的波谷 $F1(F3)$ 越来越低并且向右移动,波峰 $F2(F4)$ 越来越高 (低) 并且向右移动,图 3 每条曲线峰谷之间的差值 (从波谷上升到波峰的幅度) 也随着电池的老化越来越大。综上所述可以看出 4 个特征点可能具有高 SOH 相关性。

图 3 健康特征曲线 ($F1, F2$)Fig. 3 Health feature curves ($F1, F2$)图 4 健康特征曲线 ($F3, F4$)Fig. 4 Health feature curves ($F3, F4$)

2.4 相关性分析

在此分析健康因子和电池衰减之间的相关性。皮尔逊相关系数被用来量化电池容量衰减和健康因子之间的相关性。因此,为了进一步证实健康因子与电池容量衰减相关性,采用皮尔逊相关系数计算 $F1$ 、 $F2$ 、 $F3$ 、 $F4$ 与电池容量衰减的相关性。其中绝对值越大说明相关性越强,当绝对值为 1 时则表明完全相关,图 5 为 B0005 电池各个间接特征与容量之间的 pearson 计算结果。由此可见 $F1$ 、 $F2$ 、 $F3$ 与容量具有强相关性,可以作为健康因子使用。




图 5 健康因子相关性

Fig. 5 Correlation of health factors

$$P_{\text{pearson}} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (12)$$

3 SOH 估计及结果分析

3.1 实验环境

在 MATLAB 2023A 平台上进行了实验,电池数据

来自 NASA。为了公平评估建立的 SOH 估计器的性能,采用以下验证方案:

(1) 数据集划分。将所有电池单元的数据分为四组,每组包含四个单元的数据。

对于每一组,依次将其中一个单元的数据作为测试集,其余三个单元的数据作为训练集。

(2) 交叉验证。对每组数据,进行四次训练和测试。

第 1 次训练:单元 1 作为测试集,单元 2、单元 3 和单元 4 作为训练集。

第 2 次训练:单元 2 作为测试集,单元 1、单元 3 和单元 4 作为训练集。


第 3 次训练:单元 3 作为测试集,单元 1、单元 2 和单元 4 作为训练集。

第 4 次训练:单元 4 作为测试集,单元 1、单元 2 和单元 3 作为训练集。

(3) SOH 估计与比较。对于每次测试,使用训练好的 SOH 估计器对测试集的 SOH 进行估计。估计结果与实际测量的 SOH 进行比较,评估估计器的性能。这种交叉验证方法确保每个电池单元的数据都能被独立测试,避免了训练集和测试集数据分布重叠的问题。通过多次训练和测试,可以更全面地评估估计器在不同电池数据上的泛化能力和准确性,从而提供更可靠的性能评估结果。利用 SVR 的非线性映射能力进行 SOH 估计。以 SVR、Random-forest 作为实验对照组,验证 BMAFMO-SVR 的有效性。

3.2 算法性能测试

为了验证算法的优越性,使用标准测试函数 ($F6$) 来评估 BMAFMO 算法的性能(本文使用 SSA、PSO 来与 BMAFMO 算法进行对比),如图 6 所示。将 3 个算法的种群数以及迭代次数都设置为 30 和 1 000。寻优曲线如图 7 所示。

图 6 标准测试函数 $F6$ Fig. 6 Standard test function $F6$




图 7 收敛曲线

Fig. 7 Convergence curves

由图 7 可以看出 BMAFMO 算法收敛速度要快于 SSA 与 PSO,在寻优效率方面具有一定的优势。

3.3 估计结果分析

定量分析不同方法的性能。提出了 3 种误差评估准则,平均绝对误差(MAE)和均方根误差(RMSE)。表 3 具体显示了使用 3 种方法进行 SOH 估计的误差评估。

表 3 不同方法的误差

Table 3 Errors of different methods

电池编号	方法	RMSE	MAE
B0005	BMAFMO-SVR	0.007 3	0.003 7
	SVR	0.011 9	0.010 6
	Random-Forest	0.017 6	0.016 2
B0006	BMAFMO-SVR	0.008 2	0.006 4
	SVR	0.015 4	0.011 3
	Random-Forest	0.011 0	0.008 7
B0007	BMAFMO-SVR	0.006 8	0.002 4
	SVR	0.016 5	0.010 7
	Random-Forest	0.022 9	0.013 1
B0018	BMAFMO-SVR	0.006 7	0.002 6
	SVR	0.016 9	0.010 9
	Random-Forest	0.013 9	0.010 1

由表 3 可知对电池进行的 3 组实验中 BMAFMO-SVR 方法的 RMSE 平均在 0.7%,MAE 平均在 0.3%明显优于 SVR 与 Random-Forest。结果表明 BMAFMO-SVR 方法适合于 SOH 的估计。BMAFMO 算法可以提高预测能力,并在很大程度上提升了 SVR 模型的准确率。为了直观地展示 3 种方法的比较,图 8—图 11 显示了 4 种电池的 SOH 估计曲线以及误差曲线,为了更好地验证模型的性能,在对 B0006、B0007、B0018 的测试中引入 randperm 函数对样本进行打乱,以减少过拟合,使模型更好地泛化到未见过的数据。图 12—图 15 是 4 组电池 SOH 估计的预测结果箱线图,可以看出 BMAFMO-SVR 模型的预测结果更接近真实 SOH。




图 8 B0005 的 SOH 估计的预测结果和误差
Fig. 8 Predicted results and errors of SOH estimation for battery B0005






图 9 B0006 的 SOH 估计的预测结果和误差
Fig. 9 Predicted results and errors of SOH estimation for battery B0006




(a) 估计结果




(b) 误差结果

图 10 B0007 的 SOH 估计的预测结果和误差
Fig. 10 Predicted results and errors of SOH estimation for battery B0007



(a) 估计结果



(b) 误差结果

图 11 B0018 的 SOH 估计的预测结果和误差
Fig. 11 Predicted results and errors of SOH estimation for battery B0018




图 12 B0005 的 SOH 估计的预测结果箱线图

Fig. 12 Box plot of SOH estimation predictions for B0005




图 13 B0006 的 SOH 估计的预测结果箱线图

Fig. 13 Box plot of SOH estimation predictions for B0006




图 14 B0007 的 SOH 估计的预测结果箱线图

Fig. 14 Box plot of SOH estimation predictions for B0007




图 15 B0018 的 SOH 估计的预测结果箱线图

Fig. 15 Box plot of SOH estimation predictions for B0018

4 结 论

提出了一种新的方法,用于评估锂电池的健康状态(SOH)。利用电压、容量、温度等参数作为健康特征,描述电池的退化情况。通过 Pearson 系数验证了健康因子与 SOH 之间的相关性,结果显示这些因子对电池的劣化具有良好的响应性。针对支持向量回归(SVR)参数选择不当可能导致预测精度不高的问题,研究采用了 BMAFMO 算法进行改进。

实验结果表明:BMAFMO-SVR 方法在 4 组电池实验中的误差最小,MAE 和 RMSE 的最大值均在 1% 以内。因此,该方法能更准确地估计锂电池的 SOH,对深入了解电池的退化过程具有重要意义。这一新的估计方法为锂电池的健康监测提供了有效手段,有望在电池管理系统中发挥重要作用。同时,可能存在更适配的特征组合,需要进一步探索。

参考文献(References):

- [1] Yao L, Xu S, Tang A, et al. A review of lithium-ion battery state of health estimation and prediction methods[J]. World Electric Vehicle Journal, 2021, 12(3): 113-123.
- [2] Ghalkhani M, Habibi S. Review of the Li-ion battery, thermal management, and AI-based battery management system for EV application[J]. Energies, 2022, 16(1): 185-196.
- [3] Hong J, Lee D, Jeong E R, et al. Towards the swift prediction of the remaining useful life of lithium-ion batteries with end-to-end deep learning[J]. Applied Energy, 2020, 278: 115646.
- [4] Golla-schindler U, Zeibig D, Prickler L, et al. Characterization of degeneration phenomena in lithium-ion batteries by combined microscopic techniques[J]. Micron, 2018, 113: 10-19.
- [5] Li S, Li K, Xiao E, et al. Joint SoC and SoH estimation for zinc-nickel single-flow batteries[J]. IEEE Transactions on Industrial Electronics, 2020, 67(10): 8484-8494.
- [6] Hu X, Feng F, Liu K, et al. State estimation for advanced battery management: Key challenges and future trends[J]. Renewable and Sustainable Energy Reviews, 2019, 114: 109334.
- [7] Xing L, Liu X, Luo W, et al. State of health estimation for lithium-ion batteries using IAO-SVR[J]. World Electric Vehicle Journal, 2023, 14(5): 122-127.
- [8] Lee G, Kwon D, Lee C. A convolutional neural network model for SOH estimation of Li-ion batteries with physical interpretability[J]. Mechanical Systems and Signal Processing, 2023, 188: 110004.
- [9] Lin M, Yan C, Zeng X. State of health estimation method for lithium-ion batteries via generalized additivity model and transfer component analysis[J]. World Electric Vehicle Journal, 2023, 14(1): 14-24.
- [10] Pang B, Chen L, Dong Z. Data-driven degradation modeling and SOH prediction of Li-ion batteries[J]. Energies, 2022, 15(15): 5580.
- [11] Sun H, Sun J, Zhao K, et al. Data-driven ICA-Bi-LSTM-combined lithium battery SOH estimation[J]. Mathematical Problems in Engineering, 2022, 20(22): 9645892.
- [12] You G W, Park S, Lee S. Data-driven SOH prediction for EV batteries[C]//Proceedings of the IEEE International Conference on Consumer Electronics. Piscataway: IEEE Press, 2015: 577-578.
- [13] Li Q, Li D, 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.
- [14] Deng Y, Ying H, Jiaqiang E, et al. Feature parameter extraction and intelligent estimation of the State-of-Health of lithium-ion batteries[J]. Energy, 2019, 176(2): 91-102.
- [15] Wen J, Chen X, Li X, et al. SOH prediction of lithium battery based on IC curve feature and BP neural network[J]. Energy, 2022, 261: 125234.
- [16] Shen S, Sadoughi M, Li M, et al. Deep convolutional neural networks with ensemble learning and transfer learning for capacity estimation of lithium-ion batteries[J]. Applied Energy, 2020, 260: 114296.
- [17] Wu B, Yufit V, Merla Y, et al. Differential thermal voltammetry for tracking of degradation in lithium-ion batteries[J]. Journal of Power Sources, 2015, 273(7): 495-501.
- [18] Lin M, Yan C, Wang W, et al. A data-driven approach for estimating state-of-health of lithium-ion batteries considering internal resistance[J]. Energy, 2023, 277: 127675.
- [19] Lin M, Yan C, Meng J, et al. Lithium-ion batteries health prognosis via differential thermal capacity with simulated annealing and support vector regression[J]. Energy, 2022, 250: 123829.
- [20] Deng Z, Hu X, Lin X, et al. General discharge voltage information enabled health evaluation for lithium-ion batteries[J]. IEEE/ASME Transactions on Mechatronics, 2021, 26(3): 1295-1306.
- [21] Chai Q W, Chu S C, Pan J S, et al. Applying adaptive and self assessment fish migration optimization on localization of wireless sensor network on 3-D terrain[J]. Journal of Information Hiding and Multimedia Signal Processing, 2020, 11(1): 90-102.
- [22] Zheng W M, Xu L D, Pan J S, et al. Cluster head selection strategy of WSN based on binary multi-objective adaptive fish migration optimization algorithm[J]. Applied Soft Computing, 2023, 148: 110826.

责任编辑:代小红