

DOI: 10.19344/j.cnki.issn1671-5276.2026.02.020

基于 SSA-SVR 模型的锂离子电池剩余容量预测

宋健, 李明林

(福州大学 机械工程及自动化学院, 福建 福州 350116)

摘要: 基于 SSA-SVR 算法进行锂离子电池剩余容量预测研究, 阐述支持向量回归机(SVR)的基本原理。利用麻雀搜索算法(SSA)对 SVR 关键参数进行全局寻优, 提高 SVR 预测电池剩余寿命的精度。建立 SSA-SVR 模型, 利用 NASA PCoE 研究中心电池数据进行预测试验, 与标准 SVR、基于遗传算法的 SVR 算法预测结果进行对比。结果表明: SSA-SVR 算法具有更好的预测精度和更强的泛化性。

关键词: 锂离子电池; 剩余容量; 支持向量机; 麻雀搜索算法

中图分类号: TM911 **文献标志码:** A **文章编号:** 1671-5276(2026)02-0101-07

Prediction of Remaining Capacity of Lithium-Ion Batteries Based on SSA-SVR Model

SONG Jian, LI Minglin

(School of Mechanical Engineering and Automation, Fuzhou 350116, China)

Abstract: This study predicts the remaining capacity of lithium-ion batteries by the SSA-SVR algorithm, and elaborates the basic principles of Support Vector Regression (SVR). Sparrow Search Algorithm (SSA) is utilized for global optimization of key parameters in SVR to enhance the precision of battery remaining life prediction. A SSA-SVR model is established, pre-testing is conducted using battery data from NASA PCoE demonstrate that SSA-SVR algorithm has better predictive accuracy and greater generalization capability. research center, and a comparison with standard SVR and genetic algorithm-based SVR prediction results is performed.

Keywords: lithium-ion battery; remaining capacity; support vector machine; sparrow search algorithm

0 前言

由于锂离子电池具有循环寿命长、能量密度大、自放电率低、工作温度范围广等优点, 被广泛应用于便携式终端、电动汽车、航空航天等领域^[1-3]。随着电池充放电次数的增加, 电池的实用容量会不断减少, 电池性能也会发生退化^[4-7]。如果不能及时对电池进行更换将导致设备性能退化或系统故障, 甚至引发灾难性事故。因此, 研究出能够准确预测锂离子电池剩余容量的方法对其实际应用有着重大意义^[8-10]。

目前有许多方法被用来预测锂离子电池剩余容量^[11-15], 而支持向量机(support vector machine, SVM)因具有较强的非线性和泛化性, 成为锂离子电池健康状态领域研究的热点。使用支持向量机

(SVM)算法构建了基于特征参数的剩余寿命(RUL)回归模型, 并利用支持向量回归算法进行锂离子电池 RUL 的预测^[16-18]。然而, 其预测速度和精度较低。利用遗传算法对支持向量回归机(SVR)进行全局寻优, 以改善其回归能力^[19], 但其仍存在较大误差。此外, 通过粒子群优化(PSO)算法对 SVR 参数进行寻优, 相较于蚁群算法, 具有更高精度^[20]。然而, 传统 PSO 算法容易陷入局部最小值, 导致预测结果不够准确。

本文基于支持向量回归机(support vector regression, SVR)在电池状态预测领域的优势, 利用麻雀搜索算法(sparrow search algorithm, SSA)对 SVR 关键参数进行全局寻优, 提高了 SVR 预测电池剩余寿命的精度, 并建立了 SSA-SVR 模型, 利用 NASA PCoE 研究中心电池数据, 参考了

基金项目: 国家自然科学基金资助项目(11372074)

第一作者简介: 宋健(1999—), 男, 江苏高邮人, 硕士研究生, 研究方向为锂离子电池剩余寿命和剩余容量预测, 1136197734@qq.com。

通信作者简介: 李明林(1977—), 男, 福建南安人, 副教授, 硕士生导师, 博士, 研究方向为低纳米材料物理力学性能研究及应用、机械和设备结构设计与强度分析及医疗器械设备研发, liminglin@fzu.edu.cn。

文献[21-22]的数据降维和数据预处理方法,提取出19个最能反应容量退化的特征参数作为模型输入进行了预测试验。

1 支持向量回归机算法

SVM是由VAPNIK^[23]在1995年首次提出的一种基于理论框架的算法(vapnik-chervonenkis dimension, VC维)。其采用结构风险最小化作为最优原则,并且能够获得全局最优解。SVM在处理小样本非线性问题方面表现出色,即使样本数据较少,也能提供较准确的预测效果和强大的泛化能力。因此,在锂离子电池RUL预测中,SVM受到广泛关注^[24]。

对于给定的训练数据集 $S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_i, y_i)\}$,其中 $\mathbf{x}_i \in \mathbf{R}_n$ 为输入特征向量; $y_i \in \mathbf{R}$ (\mathbf{R} 为实数集)为输出目标值, $n=1, 2, \dots, i, \mathbf{R}_n$ 为 n 维向量空间。SVR的目标是寻找函数 $g(\mathbf{x})$,使 $g(\mathbf{x})$ 与训练集的偏差小于用户定义的不敏感损失函数 ε ,同时有较高的平坦度;当 ε 较大时,支持向量的数量就较少。回归函数 $g(\mathbf{x})$ 的计算方法为

$$y = g(\mathbf{x}) = \mathbf{w}\mathbf{x} + b \quad (1)$$

式中: \mathbf{w} 为权重矢量; b 为偏差。

通过数据训练,寻找 \mathbf{w} 和 b 使式(1)结构化风险最小,引入松弛因子 ζ, ζ^* 。依据统计学结构化风险准则,可将线性回归求解问题转化为优化问题的形式:

$$\begin{cases} \min \frac{1}{2} \|\mathbf{w}\|^2 + \eta \sum_{i=1}^n (\xi_i + \xi_i^*) \\ y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \varepsilon + \xi_i \\ \mathbf{s} \cdot \mathbf{t} \cdot \mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (2)$$

式中 η ($\eta > 0$ 且 η 为常数)为惩罚因子,用于平衡算法复杂度与样本误差之间的权重,对样本中超出误差 ε 的惩罚度进行控制。

引入拉格朗日函数,SVR模型的回归函数为

$$g(\mathbf{x}) = \sum_{i=1}^n 1(\alpha_i + \alpha_i^*) K(\mathbf{x}, \mathbf{x}_i) + b \quad (3)$$

式中: $K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}\|^2}{\sigma^2}\right)$ 为满足Mercer条件的核函数,选用高斯(Gauss)径向基核函数; σ 为高斯核宽度系数; \mathbf{x}_i, \mathbf{x} 分别为训练集和测试集的特征向量; α_i, α_i^* 为拉格朗日乘子。

如果 σ 过小,则样本训练准确性一般比较高,但是泛化能力较差,容易出现过拟合现象;如

果 σ 过大,虽不容易出现过拟合现象,但是训练准确性不高。

2 麻雀搜索算法

麻雀搜索算法(SSA)是一种新颖的启发式优化算法^[25],模拟了麻雀群体在觅食和迁徙过程中的行为。该算法利用种群个体之间的协作和竞争,通过仿真麻雀群体的自然行为来寻找问题的最优解。SSA算法的核心思想是将种群划分为发现者和加入者两类,发现者负责寻找食物,为种群提供觅食区域的信息;加入者利用发现者获取食物。在自然状态下,个体间会相互监视,麻雀种群中的加入者为了提高自身的捕食率,通常会争夺高摄取量同伴的食物资源。在觅食的同时,所有个体均会对周围环境保持警惕以防天敌的到来。

1) 参数初始化。

第 i 只麻雀在搜索空间中的位置可表示为

$$\mathbf{X}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}] \quad (4)$$

式中: $i=1, 2, \dots, n$; d 为空间维度; n 为麻雀总数。

适应度矩阵展示如下:

$$\mathbf{F}_X = [f(x_1) \quad f(x_2) \quad \dots \quad f(x_n)]^T \quad (5)$$

$$\mathbf{f}(\mathbf{x}_i) = [f(x_{i,1}) \quad f(x_{i,2}) \quad \dots \quad f(x_{i,d})]^T \quad (6)$$

式中 $\mathbf{f}(\mathbf{x}_i)$ 代表第 i 只麻雀的适应度值。

2) 更新生产者位置。生产者负责提供觅食区域和方向,数量一般设置为总数的10%-20%,其位置更新公式如下:

$$\begin{cases} X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \partial & R_2 < S_T \\ X_{i,j}^t + Q \cdot L & R_2 < S_T \end{cases} \\ \partial = \exp\left(\frac{-i}{\tau \cdot i_{\text{iter,max}}}\right) \end{cases} \quad (7)$$

式中: $j=1, 2, \dots, d$; t 为当前迭代次数,为最大迭代次数且 $i_{\text{iter,max}}$ 为最大迭代次数且 $\tau \in (0, 1]$; R_2 和 S_T 分别代表警告值和安全值,其中 $R_2 \in [0, 1]$, $S_T \in [0.5, 1]$; Q 是一个遵循正态分布的随机数; L 为元素值全部为1的 $1 \times d$ 矩阵。当 $R_2 < S_T$ 时,代表环境是安全的,生产者可以进行搜索;当 $R_2 \geq S_T$ 时,表明警戒者检测到了天敌,种群需要转移到更安全的区域。

3) 更新跟随者位置。跟随者通过生产者来获取食物,其位置更新公式如下:

$$\begin{cases} X_{ij}^{t+1} = \begin{cases} Q \cdot \mu & i > n/2 \\ X_p^{t+1} + \lambda \cdot A^+ \cdot L & \end{cases} \\ \mu = \exp\left(\frac{X_{\text{worst}}^t - X_{ij}^t}{i^2}\right) \\ \lambda = |X_{ij}^t - X_p^{t+1}| \end{cases} \quad (8)$$

式中: X_p 表示目前最优发现者的位置; \mathbf{A} 表示 $1 \times d$ 的矩阵,元素为随机赋值的1或-1; $\mathbf{A}^+ = \mathbf{A}^T(\mathbf{A}\mathbf{A}^T)^{-1}$; X_{worst}^t 表示第 t 次迭代中最差的个体。当 $i > n/2$ 时,表明跟随者非常弱小,争抢不到食物,需要迁徙到其他地方;不然,则表明跟随者可以在该区域生存。值得一提的是生产者和跟随者的身份可以根据环境的变化进行转换。

4)更新警戒者位置。麻雀具有较强的反侦查能力,种群会随机选择10%-20%的麻雀作为警戒者来躲避天敌搜捕,其位置更新公式如下:

$$\begin{cases} X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot \delta & f_i > f_b \\ X_{ij}^t + K \cdot \zeta & f_i = f_b \end{cases} \\ \delta = |X_{ij}^t - X_{\text{best}}^t| \\ \zeta = \left(\frac{|X_{ij}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right) \end{cases} \quad (9)$$

式中: X_{best}^t 表示全局最佳位置; β 是服从均值为0、方差为1的正态分布的随机数; $K \in [-1, 1]$,正负表示麻雀移动方向,大小表示步长控制参数; f_i 表示当前个体的适应度值; f_b 和 f_w 分别为全局最佳和最差适应度值。当 $f_i = f_b$ 时,表明种群中间的麻雀意识到危险,需要靠近其他麻雀来减少被猎杀的风险;当 $f_i > f_b$ 时,表明麻雀处于种群的边缘,易受到捕食者的攻击。

5)实现麻雀种群的当前位置,更新最佳适应度值。

6)重复步骤(2)到步骤(5),直到迭代终止,输出最佳位置 X_{best}^t 和最佳适合度值 f_b 。如果当前迭代次数小于最大迭代次数,则对适应度值进行排序,找到当前最佳和最差个体。

3 数据来源与特征提取

本文中的数据取自美国宇航局NASA发布的锂电池数据集。研究使用的是编号为B0005和B0007的两种型号电池。它们分别经历了168次

充放电循环。这些电池在实验中录得的数据涵盖充电和放电阶段,记录的参数包括端电压、输出电流、环境温度、充电设备所测电压、充电设备所测电流、数据采集时点以及电池的剩余容量。

电池的额定容量为2 Ah,充电与放电过程采用横流和横压技术,充电阶段电流为1.5 A,充满时电压上升至4.2 V;放电时,电流维持在2 A,直到电压下降至设定的截止电压水准。在24℃的环境下对电池进行充放电循环试验,直到电池性能衰退至无法使用,实验随之结束。详细的实验条件和数据如表1所示。

表1 电池充放电实验条件

电池类型	温度/℃	充电电流/A	充电截止电压/V	放电电流/A
B5	24	1.5	4.2	2
B7	24	1.5	4.2	2

本文参照了文献[21-22]的特征参数并在其基础上深入分析各种参数随着时间演变所呈现的曲线,以辨识出哪些信息需予以保存及哪些需予以摒弃,进而从中筛选出在各种电池老化环境中,有效指示锂电池衰退状况与实际表现的关键数据点。在各种电池衰老条件中,这些数值必须依然能够确保信息的准确性与可信度。在研究电池充电和放电过程中参数变化的轨迹时,观察到无论哪个参数,其变化趋势中都会呈现出极大值、极小值或是某些“突变点”等异常现象。这里的“突变点”指的是参数曲线在某个时刻突然产生显著变化的点。譬如,初期曲线的振荡幅度不大,而后可能会忽地急转直下或飞速攀升,在这一转折处形成所谓的“突变点”,这样的节点能够有效揭示电池的真实工作表现。在每次充电和放电过程中,我们能够识别出相似的节点,这些节点有助于描述当前锂电池所处的具体状态,进而对锂电池数据集实施。具体如图1所示(本刊为黑白印刷,相关疑问请咨询作者)。




图1 电压及温度曲线图

从图1(a)可以看出,在充电过程中,电池的电

趋平稳,基本持平不动,而且随着电池经历更多次充放电循环,电压峰值出现所需时刻愈发缩短。

因此在充电电池端子电压曲线中,我们选取电压首次达到最大时的这一点为特殊点,此时的电压记为 H1,其所对应的时间记为 H2。

从图 1(b) 部分的数据显示,电压初始升高至顶峰,随后缓慢降低,每轮充电的峰值电压屡见不鲜,并且随着充电循环的增多,抵达峰值的时间逐渐缩短。因此在充电测量电压曲线中,我们选取电压首次达到最大时的这一点为特殊点,此时的电压记为 H3,其所对应的时间记为 H4。

图 1(c) 显示了电池温度初升后降的趋势,每轮充电进程中电池均会出现一次温度峰值,并且随着充放电周期的不断累积,电池达到温度顶峰所需的时长逐渐缩短。因此在充电电池温度曲线中,我们选取温度达到最大时的这一点为特殊点,此时的温度记为 H5,其所对应的时间记为 H6。降维处理。充电电池输出电流及充电测量电流,放电电池端子电压曲线详见图 2 所示。




图 2 电流及电压曲线图

从图 2(a) 可以看出,充电伊始时电流值一度稳定,随后经历快速减少并逐渐减缓下降的过程,直到电池完全充电时,电流水平逐步接近零。随着电池充放电循环的次数增加,达到“突变点”的时间越来越短。因此在充电电池输出电流曲线中,我们选取电流刚要开始急剧下降时的“突变点”为特殊点,此时的电流记为 H7,其所对应的时间记为 H8。

到“突变点”的时间越来越短。因此在充电测量电流曲线中,我们选取电流刚要开始急剧下降时的“突变点”为特殊点,此时的电流记为 H9,其所对应的时间记为 H10,恒流充电的时间为 H11。

从图 2(b) 可以看出,与输出电流走势类似,最初电流保持稳定,随后在一定时期之后开始迅速减少,继而逐渐降低速率,直到电池充电完毕时接近零值。随着电池充放电循环的次数增加,达

从图 2(c) 可以看出,在释放电能的阶段,电压开始持续减小,当降至一定的最低点之后,电压随之缓慢回升。因此在放电电池端子电压曲线中,我们选取电压下降到最低时的点为特殊点,此时的电压记为 H12,其所对应的时间为 H13。放电负载电压、放电电池温度、放电输出电流曲线如图 3 所示。




图 3 电压及电流曲线图

从图 3(a) 可以看出,放电时电压将持续减少,且在降至零前,电压会有一个最低点。因此在放电负载电压曲线中,我们选取放电负载电压在下降到 0 之前的电压最低的点为特殊点,此时的电压记为 H14,其所对应的时间为 H15。

过程中的温度变化趋势与充电过程相似,先是升高然后降低。在每次的充电过程中,电池都会出现一个温度峰值,并且随着电池充电和放电次数的增多,温度达到峰值的时间逐渐缩短。因此在放电电池温度曲线中,我们选取温度达到最大时的这一点为特殊点,此时的温度记为 H16,其所对

从图 3(b) 可以看出,我们发现电池在放电

应的时间记为 H17。

从图 3(c)可以看出,我们能够发现在整个释放电的阶段中,电流大多数时候维持在其最高放电水平,仅在放电即将完成时,电流才会突然下降至零,并且随着充电与放电循环的次数累积,这种电流急速下滑的现象出现得愈加迅速。因此在放电输出电流曲线中,我们选取电流骤降的那一点为特殊点,又因为电流的最大值是固定值并无差异,不能反映电池容量的退化程度,所以我们只选取电流骤降这一点的时间为特征参数记为 H18。

通过对电池的电压、电流及温度波形进行深入剖析,本研究自每个循环中提炼出 18 项特性,并将当下的循环次数纳入其中,标记为 H19,构筑了一个包含 19 个数据点的向量,以表征单一的充电与放电周期。所有的充放电循环所对应的向量组合成特征矩阵,然后对特征矩阵进行归一化预处理,为建模做准备。

4 基于 SSA 的 SVR 参数优化

SVR 回归能力主要取决于 SVR 参数 η 、 γ 的相互作用。本文采用 SSA 算法在全局范围内搜索 SVR 模型参数 η 、 γ 的最优组合,得到 SSA-SVR 模型,使其能够取得最优的回归性能,提高模型的预测精度。高斯核函数中的参数 γ 为

$$\gamma = \frac{1}{2 \cdot \sigma^2} \quad (10)$$

惩罚系数 η 用于平衡经验风险和置信范围之间的折衷。如果 η 设置得过高,SVR 的泛化能力会降低,导致“过学习”状态。相反,如果 η 设置得过低,可能会引起“欠学习”现象。

较大的 σ 对应较小的 γ ,导致高维特征权重的快速衰减,可能导致欠拟合。另一方面,较小的 σ 导致较大的 γ ,理论上使得任意数据的线性映射成为可能,但存在严重过拟合的风险。

选用方均根误差作为适应度函数来描述 SSA-SVR 算法的回归能力。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (\mathbf{w}(x_j) + b_j - y_j)^2} \quad (11)$$

SSA-SVR 算法的具体步骤如下:

1) 数据处理,对 NASA 数据集进行预处理,然后将预处理后的数据划分为训练集和测试集。

2) 初始化参数,种群数量 M 为 10,最优迭代次数 pop 为 100、维度 dim 为 2、 η 和 γ 取值范围为 $(0.0001, 1000]$ 并将训练样本输入到 SSA-SVR

模型中。

3) 利用 SSA 算法迭代搜索最优参数。

4) 保存最优参数,利用最优参数训练 SVR 模型,最后构建 SSA-SVR 模型,对样本数据进行预测。

5 电池剩余容量试验及 SSA-SVR 模型验证

本文试验数据为锂离子电池健康状态领域普遍采用的 NASA PCoE 研究中心的电池数据库,选用具有代表性的 B5 和 B7 两个电池的测试数据集作为试验对象,电池额定容量为 2 Ah。

利用 NASA 搭建的锂离子电池测试机床,在室温 25 °C 下进行充电、放电和阻抗试验。B5 电池和 B7 电池的容量变化曲线如图 4 所示。




图 4 B5 和 B7 电池的容量变化曲线

NASA PCoE 电池试验以电池容量退化至额定容量的 70% 作为电池寿命结束,本文参考此标准将失效阈值设置为 1.4 Ah。因 B7 电池测试试验结束时电池容量未退化至 1.4 Ah,通过分析试验数据,将 B7 电池的失效阈值定位为 1.42 Ah。

利用 B5 电池和 B7 电池的放电数据测试 SSA-SVR 模型对电池容量的预测精度,同时利用基于经验选取参数的标准 SVR 模型和基于粒子群优化的 SVR (GS-SVR) 模型进行预测,作为对比验证。

分别选取样本前 80、100、120 个周期作为训练数据,各自剩余的周期为测试数据,图 5 和图 6 为在 3 种不同训练样本下, B5 和 B7 电池剩余容量预测曲线, (a)、(b)、(c) 分别表示以 80、100、120 个周期为训练数据。

由图 5 和图 6 可看出,3 种 SVR 模型均可以较准确地预测电池的剩余电量,标准 SVR 在训练数据较小时误差较大,SSA-SVR 模型的性能优于其它两种模型。




图 5 B5 电池剩余容量预测曲线




图 6 B7 电池剩余容量预测曲线

不同模型预测性能对比 (B5 电池) 如表 2 所示。

表 2 不同模型预测性能对比 (B5 电池)

模型	TS	MAE/%	MBE/%	RMSE/%
SVR	80	1.519	1.505	1.765
	100	1.011	1.011	1.112
	120	0.698	0.693	0.754
PSO-SVR	80	1.609	1.598	1.867
	100	0.993	0.993	1.101
	120	0.641	0.633	0.698
SSA-SVR	80	0.835	0.835	0.925
	100	0.662	0.662	0.721
	120	0.480	0.480	0.520

其中:TS 表示训练样本数目;MAE 表示平均绝对误差;MBE 表示均值偏差。

从表 2 我们可以看出,随着训练周期的增加,所有模型的预测精度都有所提升。SVR 模型的方均根误差从 1.765% 降到 0.754%; PSO-SVR 模型的方均根误差从 1.867% 降到 0.698%; 而 SSA-SVR 模型的方均根误差从 0.925% 降到了 0.520%。

不同模型预测性能对比 (B7 电池) 如表 3 所示。

表 3 不同模型预测性能对比 (B7 电池)

模型	TS	MAE/%	MBE/%	RMSE/%
SVR	80	1.602	1.580	1.766
	100	0.698	0.610	0.732
	120	0.569	0.528	0.647

续表 3

模型	TS	MAE/%	MBE/%	RMSE/%
PSO-SVR	80	1.115	1.085	1.258
	100	0.427	-0.304	0.511
	120	0.398	0.351	0.471
SSA-SVR	80	-0.743	0.751	0.824
	100	0.398	0.369	0.497
	120	0.367	0.324	0.419

从表 3 我们可以看出,随着训练周期的增加,所有模型的预测精度都有所提升。SVR 模型的方均根误差从 1.766% 降到 0.647%; PSO-SVR 模型的方均根误差从 1.258% 降到 0.471%; 而 SSA-SVR 模型的方均根误差从 0.824% 降到了 0.419%。

对比表 2 和表 3 各项指标可知,在进行锂离子电池剩余容量预测时,SSA-SVR 模型的预测精度较高,预测最高方均根误差小于 1%,且最优能到 0.419%。通过以上对比试验表明:利用 SSA-SVR 模型能够进行高精度的锂离子电池剩余容量预测,满足了锂离子电池对剩余电量估计的需要。

6 结语

针对锂离子电池剩余容量难以预测的问题,本文深入分析数据集中各种参数随着时间演变所呈现的曲线,创新性地筛选出了 19 个特征参数作为模型的输入,并利用 SSA 对 SVR 模型关键参数进行全局寻优;采用 NASA PCoE 研究中心电池数据训练 SSA-SVR 模型并进行电池剩余容量预测

试验;同时与标准SVR、PSO-SVR模型进行相同容量预测对比试验。测试结果表明:SSA-SVR模型在不同情况下均表现出较好的预测精度和较强的泛化性。预测最高方均根误差小于1%,且最优能到0.419%,可为电池管理系统及其他安全系统提供可靠的数据,实现了锂离子电池剩余容量的准确预测。

参考文献:

- [1] FANYX, XIAO F, LICR, et al. A novel deep learning framework for state of health estimation of lithium-ion battery[J]. *Journal of Energy Storage*, 2020, 32: 101741.
- [2] LIMY, ZOUBB, YANY, et al. Bifunctional macromolecular design for dual interface-passivating regulation towards practical stable lithium-sulfur batteries[J]. *Journal of Energy Chemistry*, 2025, 106: 710-717.
- [3] GAO H, ZHANGYF, HAOCX, et al. Clean and tunable fabrication of ternary graphene-cobalt based promoter by chemical vapor deposition for lithium-sulfur batteries[J]. *Journal of Energy Chemistry*, 2025, 107: 194-202.
- [4] MACY, ZHAOSP, CHEN HD, et al. Intimate heterostructure electrocatalyst for functional tandem catalysts of lithium polysulfides in separator-modified lithium-sulfur batteries[J]. *Carbon Energy*, 2025, 7(8): e70033.
- [5] CAOXT, AHMAD N, ZENG CY, et al. Zirconization of LiCoO₂ for enhanced stability and oxygen deactivation in all-solid-state lithium battery cathodes[J]. *Journal of Energy Chemistry*, 2025, 106: 930-938.
- [6] FANGXF, CHENWD, HUT, et al. Federated learning empowered microgrids: Lithium battery state-of-health prediction and multi-node co-optimisation[J]. *Journal of Energy Storage*, 2025, 139: 118892.
- [7] LINHZ, LYUWT, GUOQ, et al. MSWaveFuser: A multi-scale wavelet feature fusion network for the state-of-health estimation of Lithium batteries[J]. *Journal of Energy Storage*, 2025, 138: 118754.
- [8] SUN T, WANG S Q, JIANG S, et al. A cloud-edge collaborative strategy for capacity prognostic of lithium-ion batteries based on dynamic weight allocation and machine learning[J]. *Energy*, 2022, 239: 122185.
- [9] LEEPWL, SOONKL, SOON LT. Quantum neural network and Gaussian process framework for lithium battery state of health prediction[J]. *Energy Storage*, 2025, 7(6): e70262.
- [10] ZHOUZD, ZHONGR, CAOY, et al. Lithium battery health state prediction based on sample entropy and time feature fusion[J]. *Ionics*, 2025, 31(9): 9237-9251.
- [11] YAOJQ, ZHAOHY, KOWALJ. Fast-adaptive early-stage remaining useful life prediction of lithium-ion batteries with meta-learning[J]. *Journal of Power Sources*, 2025, 660: 238569.
- [12] QIANG, HE N, YANGZQ, et al. Robust state of health estimation and remaining useful life prediction for lithium-ion battery with synchronous framework using data-driven integrated model[J]. *Computers & Industrial Engineering*, 2025, 210: 111575.
- [13] SHIBLEEMFH, LAAKSONENH. Battery-insight-PSO: a machine learning model for accurate prediction of state of health and remaining useful life in lithium-ion batteries[J]. *Future Batteries*, 2025, 8: 100114.
- [14] RUANSJ, LINYH. Electrochemical impedance spectroscopy-based deep ensemble for lithium-ion batteries remaining useful life prediction considering data imbalance and uncertainty[J]. *Journal of Energy Storage*, 2025, 140: 118797.
- [15] YUJM, CAIYY, YANGXL, et al. A parallel LTCN-PHA network for remaining useful life prediction of lithium-ion batteries[J]. *Energy*, 2025, 337: 138436.
- [16] PATIL M A, TAGADE P, HARIHARAN K S, et al. A novel multistage Support Vector Machine based approach for Li ion battery remaining useful life estimation[J]. *Applied Energy*, 2015, 159: 285-297.
- [17] SUNL, HUANGXJ, LIUJ, et al. Remaining useful life prediction of lithium-ion batteries combined with SVD-SDAE and support vector quantile regression[J]. *Discover Energy*, 2024, 4(1): 3.
- [18] CAOJ, WANGSL, FERNANDEZC. Multi-kernel support vector regression optimization model and indirect health factor extraction strategy for the accurate lithium-ion battery remaining useful life prediction[J]. *Journal of Solid State Electrochemistry*, 2024, 28(1): 19-32.
- [19] 王树坤, 黄妙华, 刘安康, 等. 基于GA-SVR模型的锂离子电池剩余容量预测[J]. *汽车技术*, 2016(10): 53-56, 62.
- [20] 王树坤, 黄妙华, 张志运. 基于PSO-SVR优化的锂离子电池剩余容量预测[J]. *武汉理工大学学报(交通科学与工程版)*, 2016, 40(2): 380-384.
- [21] 白爽. 基于深度学习的锂离子电池寿命预测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.
- [22] 栗荣燕. 基于支持向量机的锂离子电池剩余寿命预测[D]. 郑州: 郑州大学, 2022.
- [23] VAPNIK V N. An overview of statistical learning theory[J]. *IEEE Transactions on Neural Networks*, 1999, 10(5): 988-999.
- [24] 郑青根, 杨祥国, 刘冬, 等. 改进灰狼优化最小二乘支持向量机的锂电池剩余寿命预测[J]. *重庆大学学报*, 2023, 46(11): 78-89.
- [25] WEN J, JIACY, XIAGS. State of health prediction of lithium-ion batteries for driving conditions based on full parameter domain sparrow search algorithm and dual-module bidirectional gated recurrent unit[J]. *Energy*, 2025, 335: 138292.