



基于弛豫电压低频特征的锂电池容量在线评估方法

彭湃¹, 杨毅², 曹学彬³, 周琦¹, 李凯³, 喻建瑜¹, 王红军³, 徐成梅³

(¹国网江苏省电力有限公司电力科学研究院, 江苏 南京, 211103; ²国网江苏省电力有限公司, 江苏 南京 210024; ³云储新能源科技有限公司, 山东 烟台 264004)

摘要: 锂离子电池容量的准确估计是电池健康管理的关键环节, 对保障电池系统安全运行、识别潜在失效风险具有重要意义。然而, 现有容量估计方法依赖特定充放电条件、仅使用简单统计特征, 且缺乏对新样本的快速适应能力, 导致预测精度与泛化能力受限。针对这些问题, 本文提出了一种基于弛豫电压低频特征的锂离子电池容量在线评估方法。该方法通过对电池弛豫电压信号进行离散小波变换, 提取能量、熵和标准差等低频特征。在此基础上, 采用增量支持向量回归实现新样本的在线更新, 并结合粒子群优化对超参数进行自适应调整, 显著提升了模型的预测精度与稳定性。实验结果表明, 与传统统计特征方法及多种主流机器学习模型相比, 本方法在估计精度与鲁棒性方面均具备显著优势, 平均绝对百分比误差为 0.58%, 在多样化工况新样本接入时误差仍能保持在 2% 以下, 表现出良好的泛化能力与快速适应性能。本研究为电池容量高精度在线估计提供了有效技术方案, 也为复杂应用场景下的电池健康管理和寿命预测奠定了基础。

关键词: 锂离子电池; 弛豫电压; 离散小波变换; 容量评估; 增量支持向量回归; 粒子群优化

doi: 10.19799/j.cnki.2095-4239.2026.0226

中图分类号: TM 911

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-11

Online Capacity Estimation Method for Lithium-Ion Batteries Based on Low-Frequency Features of Relaxation Voltage

Peng Pai¹, Yang Yi², Cao Xuebin³, Zhou Qi¹, Li Kai³, Yu Jianyu¹, Wang Hongjun³, Xu Chengmei³

(¹Electric Power Research Institute, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, China; ²State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211124, China; ³BatteryCloud New Energy Technology Co., Ltd, Yantai 264004, Shandong, China)

Abstract: Accurate estimation of lithium-ion battery capacity is central to battery health management and is essential for ensuring the safe operation of battery systems and identifying potential failure risks. However, existing capacity estimation methods rely on specific charge-discharge conditions, utilize only simple statistical features, and lack the ability to quickly adapt to new samples, resulting in limited prediction accuracy and generalization capability. To address these issues, this study proposes an online capacity estimation method for lithium-ion batteries based on low-frequency features of relaxation voltage. This method extracts low-frequency features such as wavelet energy, wavelet entropy, and standard deviation by performing a discrete wavelet transform (DWT) on the battery relaxation voltage

收稿日期: 2026-03-20; 修改稿日期: 2026-05-06。

基金项目: 国家重点研发计划资助项目 (2023YFB2407904); 国网江苏省电力有限公司科技项目 (J2024210)。

第一作者: 彭湃 (1993—), 男, 博士研究生学历, 中级工程师, 研究方向为新能源、储能技术与试验, E-mail: vampirerichie@163.com; 通信作者: 彭湃, 中级工程师, 研究方向为新能源、储能技术与试验, E-mail: vampirerichie@163.com。

引用本文: 彭湃, 杨毅, 曹学彬, 等. 基于弛豫电压低频特征的锂电池容量在线评估方法[J]. 储能科学与技术, XXXX, XX(XX): 1-11.

Citation: Peng Pai, Yang Yi, Cao Xuebin, et al. Online Capacity Estimation Method for Lithium-Ion Batteries Based on Low-Frequency Features of Relaxation Voltage[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-11.

signal. Furthermore, Incremental Support Vector Regression (ISVR) is employed to enable online model updates with new samples, and Particle Swarm Optimization (PSO) is used to adaptively adjust hyperparameters, significantly improving prediction accuracy and stability. Experimental results demonstrate that, compared with traditional statistical feature-based methods and various mainstream machine learning models, the proposed approach exhibits significant advantages in both estimation accuracy and robustness. It achieves a mean absolute percentage error (MAPE) of 0.58%, and maintains an error below 2% even when new samples are introduced under diverse operating conditions, showcasing strong generalization capability and rapid adaptability. This study provides an effective technical solution for high-accuracy online estimation of battery capacity and lays a foundation for battery health management and lifetime prediction in complex application scenarios.

Keywords: lithium-ion battery; relaxation voltage; discrete wavelet transform; capacity assessment; incremental support vector regression; particle swarm optimization

锂离子电池作为新一代高效能量存储装置,具有能量密度高、循环寿命长、输出电压高、无记忆效应和环境友好等优点,被广泛应用于储能系统^[1-2]。在清洁能源需求增长和政策支持的双重驱动下,电池储能系统的应用范围不断扩大,从电动汽车到大型储能电站,锂离子电池在能源转型和可再生能源消纳中发挥着越来越重要的作用^[3-5]。在电池性能指标中,容量是最核心的健康状态表征之一。容量的准确评估不仅关系到电池剩余可用能量的判断,也直接影响电池管理系统的能量调度、寿命预测与安全管理。随着锂离子电池在电动汽车、便携式设备和大规模储能系统中的广泛应用,如何在复杂工况下实现容量的精准评估已成为研究热点^[6]。

现有研究在电池容量估计方面已提出多种方法^[7-10],主要包括以下几类:基于库伦积分的方法、基于模型的方法、基于数据驱动和机器学习的方法。基于库伦积分的直接测量方法通常在设定倍率下对电池实施一次完整的充放电过程,并通过电流积分获得其额定容量。该方法原理清晰,操作简便,但测试周期较长,难以满足在线应用需求,因此多用于实验室测试或出厂容量标定。等效电路模型(Equivalent Circuit Model, ECM)或电化学模型(Electrochemical Model, EM)可通过参数辨识来推断电池容量^[11-12]。Eddahech等^[13]利用电化学阻抗谱(Electrochemical Impedance Spectroscopy, EIS)对电池在不同退化状态下的特性进行研究,结果表明实部阻抗与老化程度密切相关,并据此进行电池容量估计。尽管基于EIS的方法能够有效反

映电池在老化过程中的微观变化,预测精度较高,但其对测试平台和计算资源的要求较高,限制了应用范围。Li等^[14]对电池在多种工况下的容量衰退特性曲线进行拟合,随后引入等效电路模型表征电池动力学特性,并利用改进的粒子滤波方法对状态参数进行估计,从而实现容量的预测。基于模型的方法能够反映电池的动力学特性,但需要复杂的建模和参数估计过程,对温度、倍率等工况高度敏感,难以在多场景应用中保持稳定性^[15]。随着大数据与人工智能的发展,神经网络(Neural Network, NN)、随机森林(Random Forest, RF)、梯度提升回归(Gradient Boosted Regression, GBR)、支持向量机(Support Vector Machine, SVM)等方法被广泛用于容量估计^[16-19]。Pan等^[20]通过分析电池在恒流充电阶段端电压随老化状态的变化规律,提出了一种基于多健康指标和极限学习机(Extreme Learning Machine, ELM)的电池容量估计方法,可在不同负载条件下实现容量衰减的高效预测。Widodo等^[21]利用放电电压的样本熵作为健康特征,并采用SVM进行建模,实现了对电池容量的估计。

对于机器学习驱动的容量估计,从电池运行数据中提取典型特征并建立其与容量之间的映射关系至关重要。这些特征能够有效反映容量衰退趋势和退化规律,是实现容量准确估计的基础。相比于直接测试或电化学模型法,数据驱动方法依赖特征量化信息,因此选择与电池容量密切相关、易于获取且稳定的特征,对于提升预测精度和模型稳定性具

有决定性作用。莫易敏等^[22]分析了电池各参数全生命周期变化曲线,计算其与电池容量之间的皮尔逊相关系数,选择电池电压、内阻、等压降时间等6个强相关健康因子建立LSTM神经网络模型。Li等^[23]通过容量增量(Increment Capacity, IC)曲线峰值特征参数进行电池容量预测。韦海燕等^[24]提出以欧姆内阻增加量、极化内阻增加量和极化电容减少量作为电池的健康因子。尽管基于充放电数据的特征提取方法在理论上可实现较好的容量估计效果,但实际运行中难以获取稳定的完整数据。相比之下,电池在充放电停止后的弛豫阶段,蕴含了与容量及内部动力学相关的丰富信息^[25],该阶段数据采集相对简单,容易获取,且不受复杂负载工况的强烈干扰,为容量估计提供了一条更加便捷且可靠的途径。基于这一特点,已有学者利用弛豫阶段的电压变化规律提取老化特征,并用于锂电池容量估计与老化建模,验证了该思路的可行性。Zhang等^[25]提出了一种基于弛豫电压的卷积神经网络(Convolutional Neural Network, CNN)模型,以充电结束后的弛豫电压曲线为输入,利用迁移学习实现不同电池数据间的知识迁移,并通过贝叶斯优化自动选择模型超参数,取得了较低的预测误差。王海瑞等^[26]从完全充电后的弛豫曲线中提取包括方差、偏度、最大值等统计特征,并建立多尺度特征融合卷积模型实现了电池容量估计。现有基于弛豫电压的容量估计方法虽然验证了弛豫阶段信息的有效性,但仍存在一定局限性。一是现有方法多是直接利用弛豫电压曲线或简单的统计特征作为模型输入,难以充分挖掘信号中的多尺度动态信息,同时也缺乏对测量噪声或扰动的抑制能力。另外是缺乏针对新样本和不同工况的在线更新机制,当电池运行条件变化时,模型的适应能力和泛化性能受到限制。针对现有方法的不足,本文提出了一种结合弛豫电压低频特征与粒子群优化(Particle Swarm Optimization, PSO)增量支持向量回归(Incremental Support Vector Regression, ISVR)的在线容量估计方法。首先对电池弛豫电压信号进行离散小波变换(Discrete Wavelet Transform, DWT),从低频近似分量中提取能量、熵和标准差等老化特征。随后,采用增量学习策略将SVR模型转化为在线更新模式,实现对新样本的在线更新。同时,使用粒子群算法对模型参数进行优化,

以提升模型整体性能;最后,通过对比实验验证了所提方法在容量估计精度和泛化能力方面的有效性。

1 电池测试及老化特征提取

1.1 电池测试

为了建立准确的容量评估模型并验证所提出方法的有效性,需要对电池进行老化及性能测试。首先搭建了如图1所示的电池测试平台,平台主要由待测试的锂离子电池样本,用于模拟电池充放电过程的新威电池测试系统、模拟电池使用环境的可编程环境箱以及存储和信息交换的计算机组成。测试系统能够在恒流/恒压模式下对电池进行精确充放电控制,并记录电压、电流与容量等关键数据,保证采集数据的准确性与可靠性。为了建立准确的电池容量评估模型,采用了198个不同容量状态的磷酸铁锂(LiFePO_4)电池单体作为研究对象,其具体信息如表1所示。电池容量测试方案如图2所示:首先把电池剩余电量放空,以1/3 C的倍率放电到截止电压2.0 V,静置1小时;然后以1/3 C的电流倍率恒流充电到截止电压3.65 V,随后转为恒压充电,截止电流设为0.05 C;充电完成后静置1 h;最后以1/3 C的电流倍放电到截止电压2.0 V,以放电过程中输出的容量作为电池的最大可用容量。




图1 锂离子电池测试平台

Fig. 1 Lithium-ion battery test experimental platform

表1 电池参数

Table 1 Battery parameters

项目	参数
电芯容量/Ah	1.4
标称电压/V	3.2
电压范围/V	2.00-3.65

如图3所示,所测试电池的容量分布在1.03 Ah至1.36 Ah之间,对应健康状态覆盖范围从



图2 容量测试步骤

Fig. 2 Capacity test steps

73.5%至97.1%，体现出较强的样本多样性与代表性。由图4可见，整体容量分布稳定且连续，保证了样本集的全面性与均衡性，为容量估计模型的精确训练提供了充分的数据基础。




图3 容量测试结果

Fig. 3 Capacity test results




图4 容量分布情况

Fig. 4 Capacity distribution

1.2 老化特征提取

在电池静置阶段，从电化学机理上看，本质上是由非平衡极化状态向热力学平衡状态恢复的过程。电流切断后，欧姆极化会迅速消失，而电荷转

移极化与浓差极化则在较长时间尺度内逐步释放，因此共同决定了弛豫电压曲线的整体演化形态。随着电池老化，活性锂损失、SEI膜增厚、界面阻抗增加以及扩散阻力上升等因素，会改变极化的建立与释放过程，从而影响弛豫电压的变化幅值、恢复速率和曲线复杂度^[25-26]。如图5所示，可以看出不同容量的弛豫电压曲线呈现出差异化的特征，随容量的下降，电压曲线呈现下降的趋势，但并非严格的线性关系。原始弛豫电压曲线同时混合了整体缓慢变化趋势、局部瞬态波动以及采样噪声等多种成分，若直接作为模型输入，容易导致与容量退化相关的慢动态信息被高频扰动掩盖，不利于模型稳定提取有效老化特征。相较而言，低频分量能够更集中地保留由极化释放和扩散平衡主导的慢变信息，不仅有助于削弱噪声干扰、提升特征鲁棒性，还能够在保留容量相关演化规律的同时实现对原始信号的有效压缩，因此更适合作为容量估计模型的输入特征。




图5 弛豫电压曲线

Fig. 5 Relaxation voltage curve

离散小波变换 (DWT) 是一种将时域信号分解为多个频带的分解技术，它同时具备时域与频域的局部化分析能力，能够在高频段获得较好的时间分辨率，在低频段获得较好的频率分辨率，因而特别适用于弛豫电压这类缓慢变化但又含有局部波动的信号。因此，本文采用DWT对其进行多尺度分解，以提取不同频段的特征成分。对于弛豫电压序列 $V(t)$ ，进行离散小波变换分解的具体过程如下：

$$V(t) = \sum_{j=1}^J \sum_k D_{j,k} \cdot \psi_{j,k}(t) + \sum_k A_{j,k} \cdot \phi_{j,k}(t) \quad (1)$$

式中 j 为分解层数， k 为平移参数，代表在时域内的位置， $\psi_{j,k}(t)$ 为第 j 层下的小波函数，用于提取高频细节， $\phi_{j,k}(t)$ 为第 j 层尺度下的尺度函数，用

于捕捉低频近似成分， $D_{j,k}$ 为第 j 层的小波系数，表示高频细节信息， $A_{j,k}$ 为第 j 层的尺度系数，表示低频趋势成分。

在离散实现中，小波变换通过滤波器组，一对低通和高通滤波器对信号进行分解与重构。如图6中展示了离散小波变换过程的示意图，分解过程表示为：

$$\begin{cases} A_j[n] = \sum_k h[k] \cdot A_{j-1}[2n - k] \\ D_j[n] = \sum_k g[k] \cdot A_{j-1}[2n - k] \end{cases} \quad (2)$$

式中， $A_j[n]$ 为第 j 层的低频近似分量； $D_j[n]$ 为第 j 层的高频细节分量； $A_{j-1}[n]$ 为 $j-1$ 层的近似系数， $h[k]$ 为小波低通滤波器系数， $g[k]$ 为小波高通滤波器系数。




图6 离散小波变换过程示意图
Fig.6 Schematic diagram of the DWT

本文使用小波函数 Daubechies-6 (db6) 对静置电压信号 $V(t)$ 进行多层离散小波分解。以第 j 层低频分量为例，通过式(3)提取能量、熵、标准差三类老化特征：

$$\begin{cases} E = \sum_n |A_j[n]|^2 \\ H = -\sum_n \left(\left(\frac{|A_j[n]|}{\sum_n |A_j[n]|} \right) \cdot \log_2 \left(\frac{|A_j[n]|}{\sum_n |A_j[n]|} \right) \right) \\ \sigma = \sqrt{\frac{1}{N} \sum_n (A_j[n] - \bar{A}_j[n])^2} \end{cases} \quad (3)$$

式中 E 为能量特征， $A_j[n]$ 为第 j 层低频近似分量， H 为熵特征， σ 为标准差特征， N 为采样个数， $\bar{A}_j[n]$ 为第 j 层低频近似分量的均值。能量可以反应弛豫电压低频分量的整体强度，表征弛豫过程中能量积累情况。熵刻画了电压弛豫信号的不确定性和复杂度，能够反应不同老化状态下的电压演化规律。标准差作为统计特征可以量化低频分量的波动幅度，可以表征弛豫过程中整体变化程度的差异。

为了进一步验证所提取老化特征的有效性，通过式(4)计算老化特征与电池容量的相关系数来评估其表征能力。

$$R = \frac{\text{cov}(F, Y)}{\sigma_F \sigma_Y} \quad (4)$$

式中 R 为相关系数，绝对值越大说明特征与容量的相关性越强，表明该特征对容量衰减规律的反映越显著，对容量估计模型的贡献也越大。 F 、 Y 分别为老化特征和对应的容量值， σ_F 和 σ_Y 分别为两个变量的标准差， $\text{cov}(F, Y)$ 表示协方差。

图7为第3层至第7层低频近似分量所提取特征与容量的相关关系，随着分解层数由3增加至7，能量、熵和标准差特征与容量的相关性整体增强，说明较高层低频分量能够更充分地保留与容量退化相关的慢动态信息。当分解层数增加至第7层时，相关性提升已不明显，部分特征甚至略有回落，说明过高层分解可能导致有效老化信息被过度平滑。不同分解层数对模型结果的影响将在模型验证中进一步讨论。




图7 老化特征与容量的相关性

Fig.7 Correlation between features and capacities

2 基于 PSO-ISVR 的容量评估模型

2.1 模型总体框架

如图8展示了基于弛豫电压特性分析与 PSO-ISVR 融合算法的电池容量估计系统架构，该系统采用离线建模与在线更新相结合的双层处理机制。在离线建模阶段，首先采集历史电池样本在充电结束后的弛豫电压序列，并采用离散小波变换对信号进行多尺度分解，从低频近似分量中提取能量、熵和标准差等特征，构建老化特征向量。随后，对特征数据进行标准化处理，并将其输入 ISVR 模型。

考虑到 ISVR 模型的预测性能对惩罚系数 c 、核函数参数 γ 以及不敏感参数 ε 较为敏感, 本文进一步引入 PSO 算法对上述超参数进行全局搜索, 以获得具有较优泛化性能的初始容量估计模型。在线估计阶段, 针对实时采集的电池弛豫数据, 进行特征提取与标准化处理, 并将其输入 PSO-ISVR 模型进行容量预测。当新的容量标签样本到达时, ISVR 模型利用增量学习机制对支持向量集合与回归参数进行局部更新, 无需重新训练全量数据, 即可实现模型的逐步优化。通过 PSO 参数优化与在线 ISVR 动态更新相结合, 该框架能够在保证计算效率的同时兼顾模型精度和适应性, 从而实现对电池容量的高精度在线估计。




图8 基于 PSO-ISVR 的锂电池容量估计框架

Fig.8 Lithium battery capacity estimation framework based on PSO-ISVR

2.2 在线 ISVR 估计模型

SVR 是一种基于统计学习理论的机器学习算法, 其基本思想是通过结构风险最小化原则, 在保证模型复杂度可控的同时尽可能减小回归误差, 因此在小样本、非线性回归问题中具有一定的泛化能力^[27]。图9为 SVR 网络结构的示意图, 假设一组样本 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 其中 $x_i \in R^n$ 为 n 维特征向量, $y_i \in R$ 为对应的容量值。SVR 的目标是找到一个回归函数 $f(x) = w^T \phi(x) + b$ 尽可能地使样本与之拟合, 其中 $\phi(x)$ 是将原始输入空间映射到高维特征空间的非线性映射函数, w 是权重向量, b 是偏置项。

通过引入一个不敏感损失参数 ε , 若预测值




图9 SVR 模型网络结构

Fig.9 Network structure of SVR model

$f(x)$ 与真实值 y 之间的偏差绝对值不大于 ε , 则不计算损失。该问题可转化为求解以下优化问题:

$$\begin{aligned} \min_{w, b, \xi_i^*, \xi_i} & \frac{1}{2} \|w\|^2 + c \sum_{i=1}^N (\xi_i^* + \xi_i) \\ \text{s.t.} & \begin{cases} w^T \phi(x) + b - y_i \leq \varepsilon + \xi_i^*, i = 1, 2, \dots, N \\ y_i - w^T \phi(x) - b \leq \varepsilon + \xi_i^*, i = 1, 2, \dots, N \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, N \end{cases} \end{aligned} \quad (5)$$

式中, $c > 0$ 为惩罚系数, 用于权衡模型复杂度与训练误差; ξ_i^* 和 ξ_i 为松弛变量, 它表示可以允许部分样本点偏离 ε 带, 定义了对预测误差的接受范围。

通过引入拉格朗日乘子和核函数将上述凸优化问题转换在对偶形式下求解:

$$\begin{aligned} \min_{\beta, \beta^*} & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N k(x_i, x_j) (\beta_i - \beta_i^*) (\beta_j - \beta_j^*) - \\ & \sum_{i=1}^N y_i (\beta_i - \beta_i^*) + \sum_{i=1}^N \varepsilon (\beta_i + \beta_i^*) \\ \text{s.t.} & \sum_{i=1}^N (\beta_i^* - \beta_i) = 0, i = 1, 2, \dots, N \\ & 0 \leq \beta_i^*, \beta_i \leq c, i = 1, 2, \dots, N \end{aligned} \quad (6)$$

其中, β_i 和 β_i^* 为拉格朗日乘子, $k(x_i, x_j)$ 为核函数。鉴于上一章节老化特征与容量的非线性关系, 采用径向基函数 RBF 作为核函数, 表示如下:

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\gamma^2}\right) \quad (7)$$

式中 γ 为核函数参数, 可以控制单个样本对模型的影响范围。最终的容量估计模型可以表示为:

$$f(x) = \sum_{i=1}^N (\beta_i - \beta_i^*) k(x, x_i) + b \quad (8)$$

式中的 β_i 、 β_i^* 以及对应的样本 (x_i, y_i) 为支持向量集。

SVR 是一种离线训练方法, 当电池运行过程中出现了完整的充放电过程或通过标定获得了新样本时, 需要重新训练整个模型, 无法完成在线模型更新。本文在 SVR 模型的基础上将其扩展到在线学

习场景，通过 ISVR 在新样本到达时对支持向量集合和参数进行动态修正，实现电池容量模型的在线更新。

假设 t 时刻，模型的一组支持向量集为 $S_t = \{(x_i, y_i, \beta_i, \beta_i^*)\}$ ，其对应的容量估计模型为：

$$f_t(x) = \sum_{i \in S_t} (\beta_i - \beta_i^*) k(x_i, x_j) + b_t \quad (9)$$

当新的样本 $D_{new} = \{(x_j, y_j)\}_j^M$ 到来时，首先判断新样本是否会对原模型产生影响。将新样本代入原模型函数 (9) 计算预测值 $\hat{y}_j$ ，并进行最优性计算：

$$\begin{cases} \hat{y}_j - y_j > \varepsilon \Rightarrow \beta_j = 0, \beta_j^* = C \\ |\hat{y}_j - y_j| \leq \varepsilon \Rightarrow \beta_j = 0, \beta_j^* = 0 \\ \hat{y}_j - y_j < -\varepsilon \Rightarrow \beta_j = C, \beta_j^* = 0 \end{cases} \quad (10)$$

若满足式 (10) 中的条件，则该样本落在 ε 不敏感区内，不影响原函数的模型参数，不进行模型参数更新；如果不满足条件，将其与原支持向量集合并得到新的工作集合 W ，新的优化问题变为：

$$\begin{aligned} \min_{\beta, \beta^*} & \frac{1}{2} \sum_{i \in W} \sum_{j \in W} k(x_i, x_j) (\beta_i - \beta_i^*) (\beta_j - \beta_j^*) - \\ & \sum_{i \in W} y_i (\beta_i - \beta_i^*) + \sum_{i \in W} \varepsilon (\beta_i + \beta_i^*) \\ \text{s.t.} & \sum_{i \in W} (\beta_i^* - \beta_i) = 0 \\ & 0 \leq \beta_i^*, \beta_i \leq c, i \in W \end{aligned} \quad (11)$$

该问题的求解规模远小于基于全部数据的批量学习，极大地提升了计算效率。通过求解式 (11) 得到新的拉格朗日乘子，若某个样本的 $\beta_i=0$ 且 $\beta_i^*=0$ 则它不再是支持向量，被移出集合，得到更新后的支持向量集为： $S_{t+1} = \{(x_i, y_i, \beta_i, \beta_i^*)\}$ ，同时新的容量估计模型更新为：

$$f_{t+1}(x) = \sum_{i \in S_{t+1}} (\beta_i - \beta_i^*) k(x_i, x_j) + b_{t+1} \quad (12)$$

ISVR 在保留 SVR 基本框架的基础上，将模型训练方式由“基于全量数据的一次性离线训练”扩展为“基于支持向量集的局部增量更新”。在线应用时，首先采集充电静置后的弛豫电压序列，经特征提取后输入模型实时输出容量估计值；当系统通过定期标定或完整充放电测试获取真实容量标签后，当出现新样本时，并通过式 (10) 判断该样本是否落入不敏感区间；若落入该区间，则说明新样本对当前模型影响较小，无需更新参数；若超出该区间，则将该样本与当前支持向量集合共同构成新的工作集，对该局部集合通过式 (11) 重新求解优

化问题，从而更新支持向量及回归函数参数。

从应用角度看，锂离子电池容量衰退过程具有明显的非线性和时变特征。随着循环推进、倍率变化或充电截止条件变化，容量与特征之间的映射关系会发生一定程度漂移。若采用传统 SVR 进行全量重训练，不仅更新效率较低，也不利于在线部署。ISVR 能够在保留已有模型有效信息的基础上，利用少量新样本对模型进行动态修正，因此更适合用于锂离子电池容量的在线评估与持续跟踪。

2.3 基于 PSO-ISVR 的容量估计模型

尽管 ISVR 通过其在线学习机制有效解决了传统 SVR 无法动态更新新样本的问题，但其性能仍然高度依赖于超参数的选择，包括惩罚系数 c 、核参数 γ 和不敏感参数 ε 。不恰当的参数组合会导致模型陷入欠拟合或过拟合，严重影响容量估计的精度与泛化能力。本文引入 PSO 算法，实现 ISVR 超参数的自动化与最优化搜索。PSO 是一种模拟鸟群觅食行为的群体智能优化算法，其通过个体间的信息共享与协作，在复杂搜索空间中高效寻找全局最优解。

PSO 算法流程如图 10 所示，每个潜在解被视为一个粒子，整个种群由 N 个粒子构成。每个粒子 i 在 D 维搜索空间中的位置代表一组候选的超参数组合 $x_i = (c_i, \gamma_i, \varepsilon_i)$ ，其飞行速度记为 $v_i = (v_{i1}, v_{i2}, v_{i3})$ 。每个粒子根据自身历史最优位置 P_{best} 和种群全局历史最优位置 G_{best} 来更新自己的状态，其更新公式如下：

$$\begin{cases} v_{id}(t+1) = qv_{id}(t) + \eta_1 r_1 [p_{id} - z_{id}(t)] + \eta_2 r_2 [p_{gd} - z_{id}(t)] \\ x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \end{cases} \quad (13)$$

式中 q 为惯性权重，平衡全局与局部搜索能力； η_1 和 η_2 为学习因子，分别调节粒子向个体最优和群体最优方向飞行的步长； r_1 和 r_2 为 $0 \sim 1$ 范围内的随机数，增加搜索的随机性。当找到最优解或达到设定的最大迭代次数时，算法将终止。

3 模型验证与结果分析

为全面评估所提出的基于弛豫电压低频特征与 PSO-ISVR 算法的电池容量估计方法的性能、优越性与泛化能力，设计了多组对比实验进行验证。首先，针对不同老化状态的 198 节电池，通过实验验证基于 PSO-ISVR 的容量估计模型的效果，探讨了




图10 PSO算法流程

Fig.10 Flow of PSO algorithm


不同分解层下的低频特征对模型估计精度的影响；其次，通过不同工况的新样本接入实验评估容量估计模型的在线适应能力与泛化性能。最后，将所提方法与传统统计特征模型及主流数据驱动算法进行横向对比。

3.1 容量估计结果验证

在198节不同老化的电池中随机选取80%数据作为模型的离线训练样本，剩余20%作为测试样本验证模型的精确度。以分解层数 $J=6$ 为例对弛豫电压数据提取老化特征 F ，其中静置弛豫时间为1小时，电压采样频率为1Hz。然后以老化特征作为模型输入，容量作为输出进行模型训练。本工作是由Python3.10搭建，硬件环境为CPU: Intel(R) Core(TM) Ultra 7，内存32GB，GPU: NVIDIA RTX 500Ada。分别验证由经验值确定的参数以及基于PSO优化参数的模型估计结果。粒子群规模设为50，最大迭代次数设为50。惯性权重采用线性递减策略，初始值设为0.9，随迭代推进逐步衰减至0.2，以平衡全局搜索与局部开发能力，学习因子均设为2.0，PSO算法搜索得到的最优超参数组合为 $c=64$ ， $\gamma=0.125$ ， $\varepsilon=0.01$ 。采用平均绝对误差（MAE），平均相对误差（MAPE）以及均方根误差（RMSE）进行模型性能评估，计算公式如下：


$$\begin{cases} MAE = \frac{1}{N} \sum_{i=1}^N |\hat{Q}_i - Q_i| \\ MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{Q}_i - Q_i|}{Q} \\ RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |\hat{Q}_i - Q_i|^2} \end{cases} \quad (14)$$

式中， $\hat{Q}_i$ 为模型估计的 Q_i 容量， Q_i 为样本真实容量， Q 为电池的额定容量，本文中 Q 为1.4。图11展示了容量估计结果，可以明显看出，通过PSO算法优化后的模型在预测精度上较未优化模型有显著提升。具体来看，未优化的ISVR模型在测试样本上的MAE为0.0209，MAPE为1.49%，RMSE为0.0238；而经过PSO优化参数后的模型，MAE降至0.0081，MAPE降至0.58%，RMSE降至0.0112。这些结果表明，PSO算法能够有效优化SVR的参数组合，从而显著提升电池容量估计模型的精度和可靠性。



(a) 容量估计结果

(a) Capacity estimation results



(b) 估计误差

(b) estimation error

图11 电池容量估计结果对比

Fig.11 Comparison of battery capacity estimation results

表2 PSO优化实验结果

Table 2 Experimental results of PSO optimization

模型	MAE	MAPE	RMSE
ISVR	0.0209	1.49%	0.0238
PSO-ISVR	0.0081	0.58 %	0.0112

为进一步探究不同分解层低频特征对容量估计模型精度的影响,本研究分别提取第3至第7层的低频近似成分作为模型输入特征进行对比分析。实验结果如表3所示,当分解层数较小时(如第3层和第4层),模型的预测误差相对较大,MAE分别为0.0380和0.0326,MAPE分别为2.72%和2.33%。当分解层数达到第5层及以上时,模型精度明显提升,MAE降至0.0132以下,MAPE低于1%。总体而言,模型性能在第5至第7层时均表现优异,说明该区间的低频特征能够兼顾信号平滑性与老化信息完整性。综合考虑模型精度与计算效率,后续模型分析均基于第6层分解结果展开。

表3 不同分解层数实验结果
Table 3 Experimental results of different decomposition layers

层数	MAE	MAPE	RMSE
3	0.0380	2.72 %	0.0562
4	0.0326	2.33 %	0.0407
5	0.0132	0.94 %	0.0171
6	0.0081	0.58 %	0.0112
7	0.0085	0.61 %	0.0126

3.2 新工况样本接入验证

实际应用中,电池充电截止电压和充电倍率会随运行策略及工况条件发生变化,从而改变充电终止时的SOC水平、极化状态和浓差分布,并进一步影响弛豫电压特征与容量之间的映射关系。为验证所提方法在工况变化下的在线适应能力,本文设计了新工况样本接入实验,在基准模型基础上逐步引入不同截止电压和不同倍率条件下的少量新样本进行在线更新。

具体而言,首先在1/3 C充电倍率、3.65 V截止电压条件下建立基准模型;随后,引入1/2 C、1 C充电倍率以及3.6 V、3.55 V截止电压工况下的新样本进行在线更新与验证。借助ISVR的增量学习机制,每种工况下引入了15%的新样本进行支持向量集的在线更新。表3结果表明,所提出的PSO-ISVR容量估计模型在不同工况条件下均具有较好的预测性能。截止电压降低至3.60 V和3.55 V时,模型的MAPE为1.51%和1.57%。截止电压下降使电池在较低SOC下结束充电,导致弛豫初始电压及极化释过程相较基准工况发生偏移,从而使低频特征分布与基模型存在差异。当充电倍率提

高至1/2 C和1 C时,模型MAPE为1.68%和1.84%。相较于截止电压变化,倍率升高会进一步增强欧姆极化和浓差极化,使电池在充电结束时偏离平衡态更明显,弛豫过程的动态变化更剧烈。尽管如此,在引入少量新样本进行在线更新后,各工况下MAPE仍控制在2%以内,表明所提方法能够有效适应工况变化,具有较好的泛化能力和在线应用潜力。

表3 新工况实验结果

Table 3 Experimental results of new working conditions

工况	MAE	MAPE	RMSE
1/3C	3.60V	0.0211	1.51%
	3.55V	0.0219	1.57%
1/2C	3.65V	0.0235	1.68%
1C	3.65V	0.0257	1.84%

3.3 特征对比实验

为验证本文提出的基于离散小波变换的低频特征在容量估计中的有效性,将其与传统弛豫电压统计特征进行对比实验。具体而言,分别以小波变换后的能量、熵和标准差作为本文特征输入,与弛豫电压曲线的均值、方差、最大值和偏度等统计特征进行对照。同时为了避免单次样本随机划分带来的偶然性,在模型训练与测试过程中,实验采用50次随机抽样重复计算,并统计平均结果。表4给出了对比实验结果,可以看出本文特征在单次实验与多次重复实验中均显著优于传统统计特征,MAE、MAPE和RMSE均保持在更低水平,小波分解能够有效提取弛豫电压低频近似分量,削弱噪声干扰并保留与容量衰减高度相关的动态信息,从而提升了模型的预测精度与稳定性。

表4 特征对比实验结果

Table 4 Experimental results of features comparison

实验项目	MAE	MAPE	RMSE
统计特征	0.0200	1.43%	0.0253
本文特征	0.0081	0.58%	0.0112
统计特征(50次均值)	0.0148	1.06%	0.0184
本文特征(50次均值)	0.0073	0.52%	0.0092

3.4 不同算法对比实验

为进一步验证本文容量估计模型的性能,本章节设计与多种典型数据驱动算法的对比实验。所有模型在相同的数据划分、特征输入与评价指标下

进行训练与测试。对比算法包括 RF、GBR 以及 CNN 等常用算法。为保证对比结果的客观性,各对比模型均在各自常用的参数空间内进行了寻优。实验结果如表 5 所示, PSO-ISVR 模型在 MAE、MAPE 与 RMSE 三个评价指标上均取得了较好的结果,相较于其它机器学习模型表现出更低的估计误差。尽管 CNN 具备强大的特征自动提取能力,但在本任务中受到数据规模及特征分布的限制,其预测性能明显低于本文提出的模型。这充分说明了本文所构建的基于 PSO-ISVR 模型在锂电池容量估计问题中具备更强的泛化能力和稳定性。

表 5 不同算法对比实验结果

Table 5 Experimental results comparing different algorithms

不同算法	MAE	MAPE	RMSE
RF	0.0134	0.96%	0.0180
GBR	0.0110	0.79%	0.0158
CNN	0.0302	2.16%	0.0430
PSO-ISVR	0.0081	0.58%	0.0112

4 结 论

本文提出了一种基于弛豫电压低频特征的锂电池容量在线评估方法。通过对电池静置弛豫电压信号进行离散小波变换,从低频近似分量中提取能量、熵和标准差三类老化特征,并结合 PSO-ISVR 模型,实现了对电池容量的在线估计。实验结果表明,所提出低频老化特征在容量预测精度上明显优于传统统计特征,50 次实验结果的平均 MAPE 提升 51%。在多样化充放电工况下,通过引入少量新样本进行在线支持向量更新,模型仍能保持较高预测精度,MAPE 在 1.51%~1.84% 之间,展现出良好的工况适应性与泛化能力。与其它主流算法对比,本文方法在精度与稳定性方面均表现出优势。综上,本文提出的方法能够在多样化工况下保持高精度与快速适应性,具有较高的潜力和可靠性。未来工作将进一步考虑温度变化对弛豫电压低频特征及容量估计结果的影响,并尝试将温度作为输入变量纳入模型;同时,针对实际在线应用中的数据获取受限问题,进一步研究降低采样频率条件下的容量估计方法,以提升模型的工程适用性。

参考文献

- [1] KENNEDY B, PATTERSON D, CAMILLERI S. Use of lithium-ion batteries in electric vehicles[J]. Journal of Power Sources, 2000, 90(2): 156-162.
- [2] 田成文, 孙丙香, 赵鑫泽, 等. 基于数据驱动的锂离子电池快速寿命预测[J]. 储能科学与技术, 2024, 13(09): 3103-3111.
TIAN C, SUN B, ZHAO X, et al. Accelerated life prediction of lithium-ion batteries using data-driven approaches[J]. Energy Storage Science and Technology, 2024, 13(09):3103-3111.
- [3] FAN E, LI L, Wang Z, et al. Sustainable recycling technology for Li-Ion batteries and beyond: challenges and future prospects[J]. Chemical Reviews, 2020, 120(14): 7020-7063.
- [4] LV X, QU Y, WANG Y, et al. A comprehensive review on hybrid power system for PEMFC-HEV: issues and strategies[J]. Energy Conversion and Management, 2018, 171: 1273-1291.
- [5] LI, X, JIANG J, Wang L, Chen D, et al. A capacity model based on charging process for state of health estimation of lithium-ion batteries[J]. Applied Energy, 2016, 177: 537-543.
- [6] HU X, ZOU C, ZHANG C et al. Technological Developments in Batteries: A Survey of Principal Roles, Types, and Management Needs[J]. IEEE Power and Energy Magazine, 2017, 15(5), 20-31.
- [7] VILSEN S B, STROE D I. Battery state-of-health modelling by multiple linear regression[J]. Journal of Cleaner Production, 2021, 290: 125700.
- [8] SUI X, HE S, MENG J H, et al. Fuzzy entropy-based state of health estimation for Li-ion batteries[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2021, 9(4): 5125-5137.
- [9] LIN M Q, WU D G, MENG J H, et al. A multi-feature-based multimodel fusion method for state of health estimation of lithium-ion model fusion method for state of health estimation of lithium-ion batteries[J]. Journal of Power Sources, 2022, 518: 230774.
- [10] TAO J, WANG S, CAO W, et al. A comprehensive review of multiple physical and data-driven model fusion methods for accurate lithium-ion battery inner state factor estimation[J]. Batteries, 2024, 10(12): 442.
- [11] PRASADN G. K, RAHN G. K, Model based identification of aging parameters in lithium-ion batteries, Journal of Power Sources, 2013, 232: 79-85.
- [12] LU J, WU T, AMINE K. State-of-the-art characterization techniques for advanced lithium-ion batteries[J]. Nature Energy, 2017,2: 17011.
- [13] EDDAHECH A, BRIAT O, et al. Remaining useful life prediction of lithium batteries in calendar ageing for automotive applications [J]. Microelectronics Reliability, 2012, 52(9-10): 2438-2442.
- [14] LI D, WANG W, ISMAIL F. A Mutated Particle Filter Technique for System State Estimation and Battery Life Prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(8): 2034-2043.
- [15] YU Q, XIONG R, YANG R, et al. Online capacity estimation for lithium-ion batteries through joint estimation method[J]. Applied

- Energy, 2019, 255: 113817.
- [16] 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 Z, YANG D, ZHANG C, et al. Online estimation of lithium-ion battery capacity Based on Polarization Decay Feature and Hybrid Neural Network with Channel Attention[J]. Transactions of China Electrotechnical Society, 2025, 40(17): 5683-5702.
- [17] 赵金诺, 王岩, 李阳. 基于随机森林模型的锂离子电池放电容量预测[J]. 电源技术, 2025, 49(09): 1958-1961.
- ZHAO J, WANG Y, LI Y. Prediction of discharge capacity of lithium ion batteries based on random forest model[J]. Chinese Journal of Power Sources, 2025, 49(09): 1958-1961.
- [18] FAN Y, XIAO F, LI C, et al. A novel deep learning framework for state of health estimation of lithium-ion battery[J]. Journal of Energy Storage, 2020, 32: 101741.
- [19] TANG A, HUANG Y, XU Y, et al. Data-physics-driven estimation of battery state of charge and capacity[J]. Energy, 2024, 294: 130776.
- [20] PAN H, LU Z, Wang H, et al. Novel battery state-of-health online estimation method using multiple health indicators and an extreme learning machine[J]. Energy, 2018, 160: 466-477.
- [21] WIDODO A, SHIM M C, CAESARENDRA W, et al. Intelligent prognostics for battery health monitoring based on sample entropy[J]. Expert Systems with Applications, 2011, 38(9): 11763-11769.
- [22] 莫易敏, 陈佳浩, 叶鹏, 等. 基于多健康因子 LSTM 的电池容量估计方法[J]. 电源学报, 2025, 13.
- MO Y, CHEN J, YE P, et al. Multi-health Factor Estimation of Battery Capacity Based on LSTM[J]. Journal of Power Supply, 2025, 13.
- [23] LI X, Yuan C, Wang Z. State of health estimation for Li-ion battery via partial incremental capacity analysis based on support vector regression[J]. Energy, 2020, 203: 117852.
- [24] 韦海燕, 陈孝杰, 吕治强, 等. 灰色神经网络模型在线估算锂离子电池 SOH[J]. 电网技术, 2017, 41(12): 4038-4044.
- WEI H, CHEN X, LV Z. Online Estimation of Lithium-Ion Battery State of Health Using Grey Neural Network[J]. Power System Technology, 2017, 41(12): 4038-4044.
- [25] ZHANG S, ZHU H, WU J, et al. Voltage relaxation-based state-of-health estimation of lithium-ion batteries using convolutional neural networks and transfer learning[J]. Journal of Energy Storage, 2023, 73: 108579.
- [26] 王海瑞, 徐长宇, 朱贵富, 等. 一种并行多尺度特征融合模型开展的基于弛豫电压的锂电池 SOH 估计研究[J]. 储能科学与技术, 2025, 14(2): 799-811.
- WANG H, XU C, ZHU G, et al. A parallel multi scale-featured fusion model for state-of-health estimation of lithium-ion batteries based on relaxation voltage[J]. Energy Storage Science and Technology, 2025, 14(2): 799-811.
- [27] VAPNIK V. An overview of statistical learning theory[J]. IEEE Transactions on Neural Networks, 1999, 10(5): 988-999.