



基于改进迟滞模型与可观测性自适应迭代CKF的储能电池SOC估计研究

李智超, 屈治国

(西安交通大学热流科学与工程教育部重点实验室, 陕西 西安 710049)

摘要: 针对储能电池迟滞效应和电压平台导致荷电状态 (SOC) 估计精度下降的问题, 提出了一种基于改进 Prandtl-Ishlinskii (PI) 迟滞模型与可观测性自适应迭代容积卡尔曼滤波 (OA-ICKF) 的 SOC 估计方法。在模型方面, 采用二次修正函数改进 PI 模型以描述开路电压的非对称迟滞特性。在算法方面, 基于开路电压-SOC 灵敏度和电压曲线斜率连续调整滤波器的 SOC 校正策略。同时引入迭代量测更新控制迭代收敛, 提高了强非线性条件下的 SOC 估计精度。采用 RegD 动态工况数据和储能电站实际运行数据对所提出的方法进行验证。RegD 工况下 SOC 估计的绝对误差维持在 2% 以内。在模型初始 SOC 与实际值存在 40% 的偏差情况下, 最大绝对误差仅为 2.06%。储能电站 0.5 C 和 0.25 C 充电工况下 SOC 估计的均方根误差分别为 0.718% 和 0.594%。在连续两次充放电的运行工况下, SOC 估计的平均绝对误差和均方根误差分别为 1.79% 和 2.10%。消融实验结果显示, 去除改进 PI 模型、OA 机制与迭代量测更新中的一个或多个组件后, SOC 估计精度显著下降, 表明上述改进模块对 SOC 估计精度的提升均不可替代。所提出的方法能够准确估计储能电池的 SOC, 为保证储能电站安全高效运行提供支撑。

关键词: 磷酸铁锂电池; 储能系统; 荷电状态; 迟滞效应建模; 可观测性自适应迭代容积卡尔曼滤波

doi: 10.19799/j.cnki.2095-4239.2026.0632

中图分类号: TM 911

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-12

State-of-charge estimation of energy storage batteries based on improved hysteresis model and observability-adaptive iterative cubature Kalman filter

LI Zhichao, QU Zhiguo

(Key Laboratory of Thermo-Fluid Science and Engineering of MOE, Xi'an Jiaotong University, Xi'an 710049, Shaanxi, China)

Abstract: To address the degradation of state of charge (SOC) estimation accuracy caused by the hysteresis effect and voltage plateau of energy storage batteries, a SOC estimation method based on an improved Prandtl-Ishlinskii (PI) hysteresis model and an observability-adaptive iterative cubature Kalman filter (OA-ICKF) is proposed. On the modeling side, a quadratic correction function is adopted to improve the PI model for characterizing the asymmetric hysteresis of the open circuit voltage. On the algorithm side, the SOC correction

收稿日期: 2026-07-20; 修改稿日期: 2026-08-31。

基金项目: 新型油气勘探开发国家科技重大专项“油气田生产系统再造技术与装备”(No. 2025ZD1406700)。

第一作者: 李智超 (1999—), 男, 博士研究生在读, 主要从事锂离子电池快充与状态估计研究, E-mail: leezc@stu.xjtu.edu.cn; 通信作者: 屈治国, 教授, 主要从事电化学储能与氢能利用等研究, E-mail: zgqu@mail.xjtu.edu.cn。

引用本文: 李智超, 屈治国. 基于改进迟滞模型与可观测性自适应迭代CKF的储能电池SOC估计研究[J]. 储能科学与技术, XXXX, XX(XX): 1-12.

Citation: LI Zhichao, QU Zhiguo. State-of-charge estimation of energy storage batteries based on improved hysteresis model and observability-adaptive iterative cubature Kalman filter[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-12.

strategy of the filter is continuously adjusted based on the open circuit voltage-SOC sensitivity index and the open-circuit voltage curve slope. Iterative measurement updates are introduced simultaneously to control the convergence to improve the SOC estimation accuracy under strongly nonlinear conditions. The proposed method was validated using RegD dynamic test data and actual operation data from an energy storage station. Under the RegD condition, the absolute error in SOC estimation remains within 2%. Even when the model's initial SOC deviates by 40% from the actual value, the maximum absolute error is only 2.06%. Under 0.5C and 0.25C charging conditions with energy storage station data, the root mean square errors of SOC estimation are 0.718% and 0.594%. Under the practical operating condition of two consecutive charge-discharge cycles, the mean absolute error and root mean square error of SOC estimation are 1.79% and 2.10%, respectively. Ablation experiments show that removing one or more components of the improved PI model, the OA mechanism, or the iterative measurement update significantly reduces the accuracy of SOC estimation, indicating that all of the aforementioned improved modules are indispensable for enhancing the SOC estimation accuracy. The proposed method accurately estimates the SOC of energy storage batteries, providing support for the safe and efficient operation of energy storage stations.

Keywords: lithium iron phosphate battery; energy storage system; state of charge; hysteresis effect modeling; observability-adaptive iterative cubature Kalman filter

随着全球能源转型的加速推进,以锂离子电池为核心的电化学储能技术在电力调峰调频和可再生能源消纳等领域发挥着日益重要的作用^[1-2]。磷酸铁锂(LiFePO_4 , LFP)电池因其循环寿命长和安全性高等优势,已成为大规模储能电站中应用最为广泛的电池类型^[3]。在储能系统的运行过程中,电池管理系统需要实时获取电池的荷电状态(state of charge, SOC)以实现合理的充放电调度和安全管控^[4]。因此, SOC 估计精度直接影响储能系统的运行效率和使用寿命,需要开发适用于储能电池的高精度 SOC 估计方法。

当前 SOC 估计方法主要包括数据驱动方法和基于模型的方法两大类^[5]。数据驱动方法利用深度学习模型直接建立电池外特性数据与 SOC 之间的映射关系,近年来受到广泛关注。Bao 等^[6]构建了 Transformer 与长短期记忆网络(long short-term memory, LSTM)的协同估计框架,利用 Transformer 提取全局长时域依赖特征并指导 LSTM 进行局部修正,在多种动态工况下取得了较高的估计精度。Zhou 等^[7]提出了融合时域与频域特征的迁移双流物理信息网络,通过嵌入电池物理约束和迁移学习提高了小样本条件下的泛化能力。Xue 等^[8]提出了融合主动学习与不确定性感知修正

的闭环估计框架,根据预测不确定性主动触发模型更新以抑制 SOC 估计误差增长。尽管上述方法取得了良好的估计精度,但数据驱动方法的性能高度依赖训练数据的数量和质量,当训练数据不足或工况条件发生变化时估计精度往往显著下降^[9]。对于大容量储能电池而言,其运行工况多样且缺乏公开的标准化数据集,获取充足的高质量训练数据面临较大困难,限制了数据驱动方法在储能领域的工程应用。

基于模型的方法可以细分为电化学机理模型和等效电路模型(equivalent circuit model, ECM)两种^[10]。前者通过对电池内部电化学反应过程进行数学描述来估计 SOC,具有较强的物理可解释性。Jiang 等^[11]在扩展单粒子模型的基础上建立了双向电化学-热耦合模型,结合扩展卡尔曼滤波(extended Kalman filter, EKF)实现了多温度条件下的高精度 SOC 估计。Wang 等^[12]采用包含电解液动态的扩展单粒子模型,结合改进的双时间尺度粒子滤波框架实现了模型参数的在线调整。Dong 等^[13]利用准二维模型生成内部电化学状态数据用于训练 LSTM 模型,虽然避免了复杂偏微分方程的在线求解,但仍然依赖于准二维模型的离线参数辨识过程。总体而言,电化学模型包含大量微观参数,

模型结构复杂且计算量大，难以满足储能电站电池管理系统对在线计算效率的要求。相比之下，ECM通过少量集中参数描述电池的外部电气特性，在保证一定精度的同时具有计算效率高的优势，适用于SOC的在线估计。Ni等^[14]系统比较了二阶RC ECM与经验模型在SOC估计中的表现，结果表明ECM在宽SOC区间内的估计精度明显优于经验模型。Li等^[15]在多种动态工况数据上比较了三种不同阶次的ECM与六种卡尔曼滤波算法的组合方案，确认了ECM结合滤波算法能够以较低的计算代价实现稳定阶段误差低于1%的SOC估计。上述研究表明，ECM在模型精度与计算效率之间取得了良好的平衡，是实现SOC在线估计的有效方法。

然而，传统ECM在构建开路电压（open circuit voltage, OCV）与SOC之间映射关系时忽略了LFP电池固有的迟滞效应。迟滞效应表现为在相同SOC下充电过程的OCV高于放电过程，两条曲线之间形成闭合的迟滞回环。这一效应会导致在同一OCV下获得不同SOC估计值。为解决这一问题，研究者提出了多种迟滞建模方法。Zhao等^[16]将Takacs迟滞模型应用于LFP电池，提升了SOC估计精度，但模型中部分参数缺乏明确的物理含义。Zhou等^[17]建立了迟滞微分方程模型，按不同SOC区间分段设置调节参数，然而这些参数主要依赖试验调试确定。Yan等^[18]采用条件生成对抗网络对迟滞效应进行建模，实现了准确的SOC估计，但该方法依赖大量覆盖多种充放电路径的迟滞实验数据。Prandtl-Ishlinskii（PI）模型作为一种基于算子的迟滞描述方法，具有结构简洁、算子物理含义明确和计算效率高的特点。Zhang等^[19]将PI模型嵌入ECM用以描述LFP电池的非对称迟滞特性，结合自适应迭代无迹卡尔曼滤波（unscented Kalman filter, UKF）实现了多温度条件下的高精度SOC估计，验证了PI模型在电池迟滞建模中的有效性。然而该研究仅在1100 mAh小容量圆柱形电池上完成了验证，尚未针对大容量储能电池开展适用性研究，PI模型在储能场景下的建模效果有待进一步考察。

除了考虑迟滞效应，对卡尔曼滤波系列算法的改进也是提升SOC估计精度的有效途径。Ji等^[20]构建了多时间尺度联合估计框架，利用EKF辨识缓慢变化的模型参数，并利用多新息UKF估计SOC，

从而提升了SOC估计的效率和精度。He等^[21]根据新息序列统计分布的变化动态调整噪声估计窗口长度，实现了过程噪声和测量噪声协方差的在线自适应更新。Peng等^[22]针对UKF在噪声统计不准确时可能出现协方差矩阵非正定和滤波发散的问题，提出了双系数强跟踪机制的改进平方根UKF，提高了SOC估计在噪声不确定条件下的抗发散能力。廉高荣等^[23]采用矩阵对角化分解替代传统容积卡尔曼滤波（cubature Kalman filter, CKF）中的Cholesky分解以保证协方差矩阵分解的稳定性，并结合噪声协方差自适应更新实现了快速变温环境下的鲁棒SOC估计。上述研究主要围绕噪声自适应和数值稳定性展开改进，但未针对LFP电池的电压平台特性提出专门的应对策略。在约30%~80% SOC的平台区域内，LFP的OCV处在3.3 V~3.4 V区间内。如此小的电压变化区间会导致滤波器难以有效利用电压信息校正SOC，导致估计精度在平台区域显著下降。如何在该平台保证SOC估计精度，仍是当前研究中亟待解决的关键问题。

针对上述问题，本研究以大容量储能电池为对象，建立了基于改进PI迟滞模型的ECM，并提出了可观测性自适应迭代CKF（observability-adaptive iterative cubature Kalman filter, OA-ICKF）算法用于实现储能电池SOC的高精度估计。通过动态工况数据和储能电站实际运行数据对所提出的方法进行验证，证明了所提出SOC估计方法的有效性。

1 模型搭建

1.1 储能电池迟滞效应建模

PI模型是一种基于算子的迟滞描述方法，具有结构简洁和计算效率高的特点，适用于电池管理系统的在线实现。经典PI模型由若干Play算子加权叠加构成，每个Play算子通过阈值参数控制其迟滞回环的宽度。设PI模型的输入为 $v(t)$ ，则单个Play算子的输出 $y_p(t)$ 定义为：

$$y_p(t) = \max\{v(t) - r, \min[v(t) + r, y_p(t - T)]\} \quad (1)$$

$$y_p(0) = \max\{v(0) - r, \min[v(0) + r, 0]\} \quad (2)$$

式中， t 为当前时刻； r 为Play算子的阈值，决定了算子迟滞回环的非线性程度； T 为采样周期。

将 n 个具有不同阈值 r_i 的Play算子进行加权叠

加, 可得到经典PI模型的总输出:

$$y(t) = \sum_{i=1}^n w(r_i) H_i[v](t) \quad (3)$$

式中, $w(r_i)$ 为 r_i 对应的权重系数; H_i 表示阈值为 r_i 的 Play 算子运算。

经典PI模型中 Play 算子的上下包络函数为线性函数, 仅适用于描述对称的饱和型迟滞特性。然而储能电池的充放电迟滞曲线通常呈现非饱和的不对称特征, 经典PI模型无法准确拟合。为克服这一局限, 本研究采用改进的PI模型, 将 Play 算子的线性包络函数替换为非线性修正函数 (γ)。改进后 Play 算子的输出定义为:

$$y_p(t) = \max\{\gamma(v(t) - r), \min[\gamma(v(t) + r), y_p(t - T)]\} \quad (4)$$

$$y_p(0) = \max\{\gamma(v(0) - r), \min[\gamma(v(0) + r), 0]\} \quad (5)$$

修正函数的选取直接影响模型对迟滞特性的拟合精度与参数辨识的复杂度。已有研究采用三次多项式作为修正函数, 包含四个待辨识系数^[19]。本研究考虑到储能电站电池管理系统计算资源有限, 故选择二次多项式作为修正函数, 其表达式为:

$$\gamma(v) = \alpha_0 v^2 + \alpha_1 v + \alpha_2 \quad (6)$$

式中, α_0 、 α_1 、 α_2 为待辨识系数。与三次多项式相比, 二次修正函数减少了一个待辨识参数, 降低了过拟合的风险。将改进的 Play 算子代入式 (3), 可得到考虑迟滞效应的 OCV:

$$U_h(t) = \sum_{i=1}^n w(r_i) H_{oi}[v](t) \quad (7)$$

式中, H_{oi} 为改进后的 Play 算子运算。模型输出 U_h 即为含迟滞效应的 OCV, 该模型以当前 SOC 及其历史变化路径作为输入, 能够自动区分充电与放电过程中的 OCV 差异, 从而为后续 ECM 提供准确的 OCV 映射。

1.2 考虑迟滞效应的 ECM

本研究采用二阶 RC ECM 描述储能电池的动态特性, 并将 1.1 节所建立的改进 PI 模型嵌入其中, 以实现 OCV 迟滞效应的准确表征。模型的结构如图 1 所示, 由开路电压源 U_h 、欧姆内阻 R_0 和两组 RC 并联网络串联组成, 两组 RC 网络分别用于描述电池的电化学极化和浓差极化过程。

根据基尔霍夫电压定律, 端电压 (U_t) 与各元件之间的关系满足式 (8) 所示的观测方程:

$$U_t = U_h - U_1 - U_2 - IR_0 \quad (8)$$

式中, U_1 和 U_2 分别为两组 RC 网络两端的极化




图1 二阶RC ECM示意图

Fig. 1 Schematic diagram of the second-order RC ECM

电压; I 为电流, 放电为正, 充电为负。 U_h 由式 (7) 所建立的改进PI模型提供, 从而克服了传统 ECM 无法反映迟滞效应的问题。

两组 RC 网络的极化电压满足以下微分方程:

$$\frac{dU_1}{dt} = -\frac{U_1}{R_1 C_1} + \frac{I}{C_1} \quad (9)$$

$$\frac{dU_2}{dt} = -\frac{U_2}{R_2 C_2} + \frac{I}{C_2} \quad (10)$$

式中, R_1 和 R_2 分别为两组 RC 网络的极化电阻; C_1 和 C_2 分别为对应的极化电容。

1.3 可观测性自适应迭代CKF算法

标准 CKF 在量测更新阶段仅执行一次状态校正。当观测方程具有较强的非线性时, 单次线性化近似可能引入显著误差, 导致状态估计精度下降。迭代量测更新通过在每个时间步内多次重复量测更新过程, 逐步逼近非线性观测函数的真实映射关系, 从而提高估计精度。设时间更新后的状态预测值为 x_p , 第 j 次迭代的状态估计值为 x_{uj} , 对应的观测预测值为 z_{uj} , 则每次迭代的状态更新为:

$$x_{uj} = x_p + K_j(U_t - z_{uj}) \quad (11)$$

式中, K_j 为第 j 次迭代计算得到的卡尔曼增益。迭代是否继续由以下代价函数准则判定:

$$\Delta x_j^T P_{uj-1}^{-1} \Delta x_j + \Delta y_j^2 S^{-1} < \Delta y_{j-1}^2 S^{-1} \quad (12)$$

式中, $\Delta x_j = x_{uj} - x_{uj-1}$ 为相邻两次迭代的状态增量; $\Delta y_j = U_t - z_{uj}$ 为第 j 次迭代的观测残差; P_{uj-1} 为第 $j-1$ 次迭代的误差协方差矩阵; S 为观测噪声方差。式 (12) 的物理含义是只有当新一轮迭代同时降低了状态偏差和观测残差的综合代价时才接受本次更新, 从而避免迭代发散。当式 (12) 不再满足或迭代次数达到预设上限时停止迭代。

在基于 ECM 的 SOC 估计中, 滤波器对 SOC 的校正能力取决于观测方程中 U_t 对 SOC 的灵敏度, 这一灵敏度主要由 OCV 曲线的斜率决定。对于

LFP 电池，在 30%~80% SOC 的平台区域内该斜率趋近于零， U_t 几乎不随 SOC 变化，系统对 SOC 的可观测性较弱。此时若过程噪声设置不当，滤波器可能引入不必要的扰动或完全依赖库仑计数而失去电压校正能力。为解决这一问题，本研究提出了基于 OCV-SOC 灵敏度的自适应过程噪声调节机制。在每个时间步，首先通过式 (13) 计算当前 SOC 处的灵敏度指标 η_k 。

$$\eta_k = \left| \frac{U_h(\text{SOC}_k + \delta) - U_h(\text{SOC}_k - \delta)}{2\delta} \right| \quad (13)$$

式中， SOC_k 为当前时间步的 SOC 预测值； δ 为差分步长。基于 η_k 对过程噪声协方差矩阵中 SOC 分量的方差 q_{SOC} 进行自适应调节：

$$q_{\text{SOC}} = q_{\text{base}} + q_g \left(\frac{\eta_k}{\eta_{\text{max}}} \right)^2 \quad (14)$$

式中， q_{base} 为 SOC 过程噪声的基础值； q_g 为自适应增益系数； η_{max} 为全 SOC 范围内灵敏度指标的最大值，用于将比值归一化到 0~1 的范围。式 (14) 体现了可观测性与过程噪声之间的协调关系，其也是 OA 机制对 SOC 校正进行连续调节的依据。 q_{SOC} 之所以能够连续调节滤波器的校正策略，主要在于卡尔曼增益的构成。 η_k 即为观测方程关于 SOC 的雅可比分量，SOC 对应的卡尔曼增益近似正比于 η_k 与先验协方差之积，并随观测噪声方差的增大而减小。在时间更新中，先验协方差由后验协方差与 q_{SOC} 累加得到，因此 q_{SOC} 直接决定先验协方差的增长速率，进而决定 SOC 校正量对新息的响应强度。在电压曲线的陡峭区域， η_k 较大， q_{SOC} 随之增大，滤波器赋予过程模型较低的置信度，促使其更积极地利用 U_t 信息校正 SOC。在平台区， η_k 趋近于零， q_{SOC} 下降为基础值 q_{base} ，先验协方差的增长受到抑制，卡尔曼增益随之减小，滤波器转而更多地信赖过程模型，避免在可观测性较弱的条件下引入无效校正。

综上所述，本研究在 CKF 的基础上进行迭代量测更新和可观测性自适应过程噪声调节，最终形成 OA-ICKF 算法。

1.4 SOC 估计流程

基于前述考虑迟滞效应的 ECM 和 OA-ICKF 算法，本研究构建了完整的储能电池 SOC 估计方法。图 2 展示了该方法的总体流程，主要包含 OA 调节和 ICKF 状态估计两个协同工作的模块。

给定电池的初始 SOC 后，算法在每个采样时间步执行以下过程。首先，OA 模块根据当前 SOC 预测值，利用改进 PI 模型通过数值差分计算灵敏度指标 η_k ，并据此自适应调节 q_{SOC} 。调节后的 q_{SOC} 随即传入 ICKF 模块。ICKF 模块的工作过程分为三个步骤。第一步为容积点生成，基于当前状态估计值 x_p 及其协方差矩阵，按照容积准则生成 $2N$ 个容积点：

$$X_i = x_p \pm \sqrt{N} \cdot [M]_i, \quad i = 1, \dots, N \quad (15)$$

式中， M 为协方差矩阵的 Cholesky 分解因子； $[M]_i$ 表示 M 的第 i 列。这些容积点在状态空间中对称分布，用于近似状态的概率分布特征。

第二步为电压修正。将各容积点经状态转移函数传播后代入观测方程，其中 OCV 由改进 PI 模型根据各容积点对应的 SOC 值和历史路径计算得到， U_t 的预测按式 (8) 完成。PI 模型的嵌入使观测方程能够自动区分充电和放电过程中的 OCV 差异，从而为后续的状态校正提供准确的电压预测基准。

第三步为迭代量测更新。根据观测预测结果计算 K_j ，按式 (11) 执行状态更新，并通过式 (12) 判断是否继续迭代。迭代收敛后输出当前时间步的 SOC 估计值，同时更新 PI 模型的内部状态以记录最新的充放电路径信息，为下一个时间步的 U_h 计算做好准备。

2 实验设计与数据来源

2.1 实验系统介绍

本研究所用电池的正极材料为 LFP，负极材料为石墨。电池的基本参数如表 1 所示，额定容量为 280 Ah，质量为 5.5 kg，外形尺寸为 170 mm×205 mm×70 mm。该电池广泛应用于电化学储能电站的电池模组中。

为完成电池特性测试和模型参数辨识实验，本研究搭建了如图 3 所示的实验系统。该系统由充放电仪、储能电池、恒温箱和控制电脑四部分组成。充放电仪用于按照预设的程序对电池施加电流。恒温箱用于为电池提供恒定的环境温度，以消除温度变化对参数辨识和性能测试结果的影响。控制电脑通过上位机软件与充放电仪通信，负责工况程序的编辑与下发以及测试数据的记录与存储。本研究所有实验均在 25℃ 恒温条件下完成。




图2 本研究SOC估计方法框架

Fig. 2 The SOC estimation framework in this study

表1 储能电池基本信息

Table 1 Basic information of the energy storage battery

电极材料	容量/Ah	质量/kg	尺寸/mm
LiFePO ₄ /石墨	280	5.5	170×205×70



图3 实验系统示意图

Fig. 3 Schematic diagram of experimental system

2.2 模型参数辨识实验方案

为获取改进PI模型和ECM的参数，本研究开展了容量测试、混合脉冲功率特性（hybrid pulse power characterization, HPPC）测试和低倍率充放电OCV测试。

容量测试用于确定电池的实际可用容量，作为后续SOC计算的基准。测试过程为以C/7恒流恒压充电至充电截止电压（3.65 V），截止电流为C/20，随后以C/7恒流放电至放电截止电压（2.5 V）。放电容量被视为电池的实际可用容量。

HPPC测试用于辨识ECM中的 R_0 、 R_1 、 R_2 、

C_1 和 C_2 五个参数。首先以C/7将电池充满电，随后按以下步骤循环执行：以100 A电流放电10 s后搁置30 s，再以100 A电流充电10 s后搁置30 s，然后以C/7恒流放电10% SOC并搁置1 h。重复上述步骤直至电池完全放电，数据采集间隔为0.1 s。

低倍率充放电OCV测试用于获取改进PI模型的参数辨识数据。在极低电流倍率下电池内部极化效应可忽略不计， U_t 可近似视为 U_h ，从而获得充电和放电两条OCV曲线，用于辨识改进PI模型中修正函数的系数 α_0 、 α_1 、 α_2 以及各Play算子的 $w(r_i)$ 。具体测试过程如下：首先以C/20恒流对电池进行充电至3.65 V，该过程仅采用恒流充电，不执行恒压阶段，以避免恒压充电末期电流衰减对OCV数据的影响。充电完成后搁置2 h以记录满充状态下的平衡电压，随后以相同的C/20电流恒流放电至2.5 V。全过程记录时间、电流和电压数据，数据采集间隔为10 s。

2.3 RegD测试与储能电站运行数据获取

为验证所提出的SOC估计方法的有效性，本研究分别采用RegD动态工况测试数据和储能电站实际运行数据进行两个层面的验证。

由于本研究的对象为储能电池而非动力电池，因此未采用其他研究中常用的美国联邦城市运行工况（FUDS）和高速与急加速工况（US06）等面向电动汽车的测试工况，而是选择了与储能电池实际应用场景更为契合的RegD测试工况。RegD测试工况为美国PJM辅助服务市场的自动调频控制信号之一，其要求调频资源几乎同步响应电网指令，具有波动频繁和功率变化剧烈的特点，适用于

储能电池等快速响应资源。本研究所用的RegD测试程序由放电和充电两个过程组成，其中放电过程包含30个电流值，充电过程包含15个电流值，各步之间的电流大小随机变化。测试从电池100% SOC开始，将上述45步电流序列重复执行6次。

在实际应用验证方面，本研究从一台总容量为20 MWh的储能电站中提取了包含时间、电流、电压和健康状态（state of health, SOH）在内的四类运行数据。数据来源为该电站中的一个电池簇，该电池簇由25个电池包串联组成，每个电池包由16个电芯串联构成。该电站与光伏系统直连，其运行模式为日间充电、夜间放电。本研究分别提取了0.5C充电、0.25C充电以及0.5C连续两次充放电三组工况数据用于模型验证。其中，由于该电站每次充电与放电之间存在较长的静置时段，为构成连续的充放电工况，提取连续充放电数据时剔除了上述静置时段。为保证SOC估计精度验证的可靠性，本研究基于提取到的运行数据独立标定SOC真值。标定过程为：首先根据电池额定容量与SOH计算当前实际可用容量。随后采用安时积分法逐时刻累计充放电容量。最后将各时刻的累计充放电容量与当前实际可用容量之比同电池初始SOC相加，得到每一时刻的SOC真值。

3 结果与讨论

3.1 模型参数辨识结果

3.1.1 改进PI模型参数辨识结果

改进PI模型的参数辨识采用双层优化策略。外层使用Nelder-Mead算法优化式(6)中的 α_0 、 α_1 和 α_2 。内层则通过岭回归法求解各算子的 $w(r_i)$ 。

辨识得到的修正函数系数为 $\alpha_0=-351519.73$ ， $\alpha_1=1406078.91$ ， $\alpha_2=939680.89$ 。19个Play算子的阈值 r_i 从0.05到0.95等间隔取值，对应的权重辨识结果如表2所示。各权重的数量级分布在 10^{-9} ~ 10^{-5} 之间，权重的符号正负交替变化，体现了不同阈值算子之间的相互补偿关系，这种分布特征使得PI模型能够通过多个算子的加权叠加精确逼近非对称的迟滞回环形状。

图4为采用上述参数后改进PI模型的 U_h 拟合结果与低倍率充放电测试实测值的对比。从图中可以看出，拟合曲线在充电和放电两个方向上均能较好地跟踪实测曲线的变化趋势，尤其是在灰色阴影区

表2 各Play算子权重辨识结果

Table 2 Weight identification results of each Play operator

r_i	$w(r_i)$	r_i	$w(r_i)$
0.05	6.26×10^{-7}	0.55	-1.05×10^{-5}
0.10	-7.32×10^{-7}	0.60	-6.31×10^{-6}
0.15	4.80×10^{-7}	0.65	-2.32×10^{-6}
0.20	-3.39×10^{-7}	0.70	2.80×10^{-7}
0.25	-1.71×10^{-9}	0.75	-1.87×10^{-8}
0.30	4.30×10^{-8}	0.80	-7.74×10^{-8}
0.35	3.70×10^{-7}	0.85	-4.08×10^{-8}
0.40	-6.59×10^{-7}	0.90	-2.86×10^{-7}
0.45	3.93×10^{-6}	0.95	3.36×10^{-7}
0.50	1.62×10^{-5}		

域标注的电压平台区，拟合曲线与实测曲线的吻合程度较高。在该区域内，拟合曲线能够反映出充放电之间的迟滞差异。整体拟合的平均绝对误差（mean absolute error, MAE）为0.011 V，均方根误差（root mean square error, RMSE）为0.023 V，表明改进PI模型能够以较高精度描述储能电池的OCV迟滞特性，可为后续SOC估计提供可靠的 U_h 值。




图4 改进PI模型拟合结果

Fig. 4 Fitting results of the improved PI model

3.1.2 ECM参数辨识结果

等效电路模型的参数辨识基于HPPC测试数据完成。对于每个SOC测试点，首先利用式(16)直接计算 R_0 。

$$R_0 = \frac{|U_i(t_1) - U_i(t_0)|}{I_{\text{pulse}}} \quad (16)$$

式中， t_0 为脉冲前静置结束时刻； t_1 为脉冲起

始时刻; I_{pulse} 为脉冲电流幅值。

随后, 对脉冲结束后的静置弛豫电压曲线进行拟合。以静置结束时刻的电压作为 OCV 的锚定值 U_{end} , 采用式 (17) 描述弛豫过程:

$$U_i(t) = U_{\text{end}} - b_i e^{-\beta t} - c_i e^{-\varphi t} \quad (17)$$

式中, b_i 和 c_i 分别为两个指数项的幅值系数; β 和 φ 分别为两个指数项的衰减速率。通过约束最小二乘法对上述四个参数进行拟合, 约束条件为所有参数为正数。拟合完成后, 由衰减速率得到两组 RC 网络的时间常数:

$$\tau_1 = \frac{1}{\beta}, \quad \tau_2 = \frac{1}{\varphi} \quad (18)$$

结合脉冲电流幅值和脉冲持续时间 Δt_{pulse} 反算极化电阻:

$$R_1 = \frac{b_i}{(1 - e^{-\Delta t_{\text{pulse}}/\tau_1}) I_{\text{pulse}}}, \quad R_2 = \frac{c_i}{(1 - e^{-\Delta t_{\text{pulse}}/\tau_2}) I_{\text{pulse}}} \quad (19)$$

最后根据式 (20) 计算极化电容:


$$C_1 = \frac{\tau_1}{R_1}, \quad C_2 = \frac{\tau_2}{R_2} \quad (20)$$

图 5 (a) 为三个电阻参数随 SOC 的变化曲线。 R_0 在 10%~80% SOC 范围内保持相对稳定, 数值在 5.4 mΩ 以下, 在 90% SOC 以上区域明显上升。这一变化规律与 LFP 电池在高 SOC 区域极化增大的特性一致。两个极化电阻 R_1 和 R_2 均随 SOC 的升高总体呈下降趋势, 且在整个 SOC 范围内 R_2 始终大于 R_1 , 表明浓差极化过程对电池动态响应的影响大于电化学反应过程。


图 5 (b) 为两个极化电容随 SOC 的变化曲线。 C_1 在 10%~90% SOC 范围内变化平缓, 数值保持在 31 kF 以内, 在 100% SOC 处上升至 65 kF。 C_2 的数值整体大于 C_1 , 从 10% SOC 处的 69 kF 上升至 100% SOC 处的 247 kF。

3.2 基于 RegD 数据的 SOC 估计准确性验证

图 6 展示了所提出的方法在 RegD 动态工况下的 U_i 预测结果与 SOC 估计结果。图 6 (a) 展示了 U_i 预测值与实测值的对比及 RegD 测试电流曲线。红色方框标注了一个由 45 步充放电电流构成的完整周期, 测试共包含 6 个周期。对于电压预测结果, 可以看到即使在充电阶段电压处于平台区时, 模型的电压预测值仍能与实测值高度吻合, 总体 MAE 为 0.0176 V, RMSE 为 0.0199 V。这表明改进 PI 模型能够为等效电路模型提供准确的 U_i , 从而提升 SOC 估计精度。



(a) 电阻辨识结果



(b) 电容辨识结果


图 5 ECM 参数辨识结果

Fig. 5 Identification results of ECM parameters


图 6 (b) 为不同初始 SOC 条件下模型估计值与实测值的对比。当模型初始 SOC 设置为与实际初始值相同的 100% 时, SOC 估计曲线在整个测试过程中基本与实测曲线重合, MAE 和 RMSE 分别为 0.728% 和 0.874%, 绝对误差 (absolute error, AE) 保持在 2% 以内。为进一步验证所提出的方法的鲁棒性, 将模型初始 SOC 设置为 60%, 与实际初始值存在 40% 的偏差。结果表明, 估计曲线能够迅速收敛至实测曲线。除收敛阶段外, SOC 估计的最大 AE 仅为 2.06%。上述结果表明, 所提出的方法不仅能在 RegD 动态工况下实现高精度 SOC 估计, 而且对初始 SOC 误差具有良好的鲁棒性。

此外, 在实际应用中, 传感器不可避免地存在偏置。为考察所提出的方法对该因素的适应能力, 在保持其余数据不变的前提下, 将 RegD 测试的放

电电流数据整体减小5 A、充电电流数据整体增大5 A，以模拟电流传感器存在偏置的情形，并开展SOC估计。由图6(b)可以看出，在存在5 A电流偏置的条件下，所提出的方法仍能准确估计SOC，MAE和RMSE分别为1.34%和1.64%，最大AE为2.97%。这表明本研究提出的方法可以应对实际应用出现的传感器偏置情况。



(a) 电池电压预测结果



(b) SOC估计结果

图6 基于RegD测试数据的模型验证

Fig. 6 Model verification based on RegD test data

3.3 基于储能电站数据的SOC估计准确性验证

为验证所提出的方法在实际工程环境中的适用性，本研究采用从储能电站提取的三组运行数据进行测试。与实验室获得的RegD测试数据不同，储能电站运行数据包含传感器精度有限和采样噪声等实际工程因素的影响，能够更真实地反映所提出的

方法的工程应用表现。

图7(a)为基于单次充电数据的SOC估计结果，上下两部分分别对应0.5C和0.25C充电工况。在0.5C充电工况下，SOC估计曲线在整个充电过程中与实测曲线保持良好的一致性，SOC估计的MAE为0.608%，RMSE为0.718%。在0.25C充电工况下，SOC估计的MAE为0.465%，RMSE为0.594%，证明所提出的方法具有良好的准确性。图7(b)为基于0.5C连续两次充放电数据的SOC估计结果。上半部分的SOC曲线显示，估计曲线在两个循环中均能跟随实测曲线的升降趋势，在充放电切换处未出现跳变，SOC估计的MAE为1.79%，RMSE为2.10%。下半部分的AE曲线显示，放电阶段估计值偏高，充电阶段估计值偏低，最大AE约为4%。该工况下误差大于单次充电工况，其原因在于充放电切换时模型内部Play算子所记录的迟滞路径与电池真实迟滞状态存在偏差，且如2.3节所述该组数据剔除了充放电之间的静置时段，模型的连续递推无法反映静置期间极化电压的弛豫过程。即便如此，第二个循环结束时估计值仍与实测值接近，表明误差未随循环进行而持续累积。上述结果表明，所提出的方法在实际工程环境下的单次充电与连续充放电运行工况中均能保持可靠的SOC估计精度，具备工程应用的可行性。

在实际工程环境中，温度波动与电池老化会引起模型参数的偏差，温度升高使内阻减小，而老化则使内阻增大。为考察上述两类因素对SOC估计精度的影响，本研究基于0.5C充电数据，分别将辨识所得内阻扩大至1.1倍以模拟电池老化、缩小至0.9倍以模拟温度上升，并开展SOC估计，结果如图7(c)所示。与不改变内阻的SOC估计结果一样，内阻缩放后的SOC估计曲线在整个充电过程中始终跟随实测曲线。在1.1倍内阻条件下，SOC估计的MAE和RMSE分别为1.71%和1.99%。在0.9倍内阻条件下分别为1.12%和1.28%。可以看出，即使内阻存在 $\pm 10\%$ 的偏差，SOC估计的MAE与RMSE仍保持在2%以内。其原因在于，内阻偏差首先体现为观测方程中 U_t 预测值的偏差，而OA-ICKF能够依据实测电压对SOC持续施加反馈校正，从而抑制该偏差向SOC估计结果的传递。




图7 基于储能电站运行数据的模型验证

Fig. 7 Model verification based on operational data of energy storage station

3.4 不同SOC估计方法对比分析

为验证改进PI模型和OA-ICKF算法各自的有效性,本研究基于RegD测试数据设计了四组消融实验,分别将本研究提出的PI+OA-ICKF方法中的一个或多个改进模块替换为基础方法,通过对比分析各模块对SOC估计精度的影响。其中,PI+CKF保留改进PI模型而将OA-ICKF替换为基础CKF。OCV+OA-ICKF保留完整的OA-ICKF算法而去除改进PI模型。为进一步评估OA机制与迭代量测更新各自的贡献,本研究设置了仅保留OA机制的OCV+OA-CKF和仅保留迭代量测更新的OCV+ICKF。

图8为五种方法在RegD工况下的SOC估计曲线对比。PI+OA-ICKF的估计曲线在整个测试过程中与实测曲线保持高度一致,而其余四种方法的估计曲线均出现了不同程度的偏离。PI+CKF在测试前期与实测值较为接近,但缺少OA自适应调节和迭代量测更新,滤波算法无法调整SOC估计校正策略,导致SOC估计误差的累积。去除改进PI模型的三种方法从初期开始其SOC估计值便低于实测值,这是因为去除改进PI模型后式(8)中的 U_n 采用充放电平均OCV曲线,无法反映储能电池的迟滞效应,由此产生的电压偏差传递至SOC校正环节,导致SOC估计出现持续偏移。在相同的OCV下,OCV+OA-ICKF的估计曲线偏离最小,OCV+OA-CKF次之,OCV+ICKF的偏离最为显著。

表3汇总了五种方法的SOC估计误差。PI+OA-ICKF的MAE、RMSE和最大误差分别为0.728%、0.874%和1.94%,均为五种方法中的最低值,而PI+CKF的MAE升至2.28%。去除改进




图8 不同SOC估计方法性能对比

Fig. 8 Performance comparison of different methods

PI模型后,OCV+OA-ICKF的MAE升至8.87%,表明迟滞效应引起的OCV偏差是SOC估计误差的主要来源。进一步比较去除改进PI模型的三种方法的误差可以考察两项滤波算法改进的贡献。移除迭代量测更新后,OCV+OA-CKF的MAE由8.87%升至11.2%,说明迭代量测更新能够抑制单次量测更新中非线性近似引入的误差。而移除OA机制后,OCV+ICKF的MAE升至16.0%,最大误差由11.3%增至32.3%,误差增幅明显更大。上述结果表明,OA机制与迭代量测更新对SOC估计精度的提升均有贡献。

上述对比结果表明,改进PI模型和OA-ICKF算法对SOC估计精度的提升均发挥了不可替代的作用。改进PI模型从模型层面消除了迟滞效应引起的OCV偏差。OA-ICKF则通过自适应过程噪声调节和迭代量测更新保障了SOC的估计精度。逐模块消融结果进一步证实改进PI模型、OA机制与迭

表3 不同方法的SOC估计误差
Table 3 SOC estimation errors using different methods

方法	MAE/%	RMSE/%	最大AE/%
PI+OA-ICKF	0.728	0.874	1.94
PI+CKF	2.28	2.65	4.61
OCV+OA-ICKF	8.87	9.00	11.3
OCV+OA-CKF	11.2	11.4	14.3
OCV+ICKF	16.0	17.8	32.3

代量测更新三个模块协同作用，缺一不可。

4 结 论

本研究针对大容量储能电池的SOC估计问题，建立了基于改进PI迟滞模型的等效电路模型，并提出了OA-ICKF算法用于SOC估计。其中改进PI模型能够有效描述储能电池OCV的非对称迟滞特性，消除了传统模型直接采用充放电平均OCV所带来的偏差。OA-ICKF算法则通过自适应过程噪声调节和迭代量测更新，实现了滤波策略随可观测性变化的连续自适应调节。模型验证表明，在RegD动态工况和储能电站0.5C和0.25C两组实际充电工况下，所提出的方法均能实现高精度的SOC估计。在连续两次充放电的运行工况下，所提出的方法的SOC估计误差同样保持在合理水平且未随循环进行而持续累积。消融实验证明改进PI模型、OA机制与迭代量测更新三个模块协同提升SOC估计精度，三者缺一不可。上述结果验证了所提出的方法在储能电池不同工况下的有效性和工程适用性。

参 考 文 献

- [1] 陈伟, 杨文春. 锂离子电池储能电站智能监测技术与运行保障[J]. 储能科学与技术, 2026, 15(6): 2316-2318.
CHEN W, YANG W C. Operational status monitoring and evaluation of lithium-ion battery energy storage stations[J]. Energy Storage Science and Technology, 2026, 15(6): 2316-2318.
- [2] ZHANG Z H, WANG H W, LU L G, et al. State-of-charge and capacity estimation for MWh-scale LiFePO₄ peak-shaving battery energy storage stations based on real-world operating data[J]. Energy, 2025, 339: 139086.
- [3] KOOHI-FAYEGH S, ROSEN M A. A review of energy storage types, applications and recent developments[J]. Journal of Energy Storage, 2020, 27: 101047.
- [4] 张可信, 胡凯, 芦勃睿, 等. 电化学储能系统中磷酸铁锂电池荷电状态估计研究[J]. 自动化应用, 2024, 65(11): 147-149.
ZHANG K X, HU K, LU B R, et al. Research on state of charge estimation of lithium iron phosphate batteries in electrochemical energy storage systems[J]. Automation Application, 2024, 65(11): 147-149.
- [5] 赵志斌, 袁鸿明, 刘炳辰, 等. eVTOL飞行器电池SOC估计: 内嵌等效电路模型的神经网络[J]. 推进技术, 2026, 47(6): 107-117.
ZHAO Z B, YUAN H M, LIU B C, et al. Battery SOC estimation for eVTOL aircraft: neural network with embedded equivalent circuit model[J]. Journal of Propulsion Technology, 2026, 47(6): 107-117.
- [6] BAO G Y, LIU X H, ZOU B S, et al. Collaborative framework of Transformer and LSTM for enhanced state-of-charge estimation in lithium-ion batteries[J]. Energy, 2025, 322: 135548.
- [7] ZHOU Y H, WANG C D, GU T C, et al. State of charge estimation of lithium-ion batteries using transfer dual-stream physics-informed network[J]. Journal of Energy Storage, 2026, 141: 119451.
- [8] XUE J W, DU X Z, ZHAO L, et al. Active-learning-driven error control for data-driven state of charge estimation across the lithium battery lifecycle[J]. Energy and AI, 2025, 21: 100549.
- [9] OH S, KIM J, MOON I. Hybrid data-driven deep learning model for state of charge estimation of Li-ion battery in an electric vehicle[J]. Journal of Energy Storage, 2024, 97: 112887.
- [10] 李清波, 张懋慧, 罗英, 等. 基于等效电路模型融合电化学原理的锂离子电池荷电状态估计[J]. 储能科学与技术, 2024, 13(9): 3072-3083.
LI Q B, ZHANG M H, LUO Y, et al. Lithium-ion battery state of charge estimation based on equivalent circuit model[J]. Energy Storage Science and Technology, 2024, 13(9): 3072-3083.
- [11] JIANG Z R, ZHANG Y F, GAO R J. An improved electrochemical-thermal coupling model for state-of-charge estimation of lithium-ion battery[J]. Energy, 2025, 333: 137486.
- [12] WANG J R, MENG J H, PENG Q, et al. An electrochemical-thermal coupling model for lithium-ion battery state-of-charge estimation with improve dual particle filter framework[J]. Journal of Energy Storage, 2024, 87: 111473.
- [13] DONG G Z, GAO G X, LOU Y J, et al. Hybrid physics and data-driven electrochemical states estimation for lithium-ion batteries [J]. IEEE Transactions on Energy Conversion, 2024, 39(4): 2689-2700.
- [14] NI Z C, JIA C. A comparative study of battery state of charge estimation with equivalent circuit model and empirical model[J]. Measurement, 2026, 258: 119162.
- [15] LI J Y, SHE C Q, BIN G F, et al. Comparative study of battery SoC estimation strategies based on fusion of equivalent circuit models and filter method in real-world scenarios[J]. Journal of Energy Storage, 2026, 157: 121683.
- [16] ZHAO X, DE CALLAFON R A. Modeling of battery dynamics and hysteresis for power delivery prediction and SOC estimation[J]. Applied Energy, 2016, 180: 823-833.
- [17] ZHOU W L, MA X Y, WANG H, et al. SOC estimation based on hysteresis characteristics of lithium iron phosphate battery[J].

- Machines, 2022, 10(8): 658.
- [18] YAN L S, PENG J, ZHU Z Y, et al. Data-driven modeling of open circuit voltage hysteresis for LiFePO_4 batteries with conditional generative adversarial network[J]. Energy and AI, 2025, 20: 100478.
- [19] ZHANG H P, HU B, YU Z L, et al. State-of-charge estimation of lithium-ion battery based on improved equivalent circuit model considering hysteresis combined with adaptive iterative unscented Kalman filtering[J]. Journal of Energy Storage, 2024, 102: 114105.
- [20] JI S Y, SUN Y, CHEN Z X, et al. A multi-scale time method for the state of charge and parameter estimation of lithium-ion batteries using MIUKF-EKF[J]. Frontiers in Energy Research, 2022, 10: 933240.
- [21] HE Z G, ZHANG X G, FU X R, et al. Research on battery state of charge estimation based on variable window adaptive extended Kalman filter[J]. International Journal of Electrochemical Science, 2024, 19: 100440.
- [22] PENG S M, ZHANG A, LIU D D, et al. State-of-charge estimation of lithium-ion batteries based on dual-coefficient tracking improved square-root unscented Kalman filter[J]. Batteries, 2023, 9(8): 392.
- [23] 廉高荣, 叶敏, 王桥, 等. 基于改进模型与优化自适应CKF的锂离子电池快速变温工况下的SOC估计[J]. 储能科学与技术, 2024, 13(5): 1667-1676.
- LIAN G Q, YE M, WANG Q, et al. State-of-charge estimation of lithium-ion batteries in rapid temperature-varying environments based on improved battery model and optimized adaptive cubature Kalman filter[J]. Energy Storage Science and Technology, 2024, 13(5): 1667-1676.