



基于物理信息引导的磷酸铁锂电池荷电状态估计方法

骆可¹, 强栋¹, 翁伟¹, 姚绒¹, 付俊成², 张轩铭³, 孟锦豪³

(¹特变电工新疆新能源股份有限公司, 新疆维吾尔自治区 乌鲁木齐 830011; ²西安交通大学国家储能技术产教融合创新平台(中心), 陕西 西安 710049; ³西安交通大学电气学院, 陕西 西安 710049)

摘要: 磷酸铁锂(lithium iron phosphate, LFP)电池在电动汽车与储能系统中应用广泛,但其电压平台区可观测性不足,表面力信号又易受温度漂移、机械滞后与老化效应耦合干扰,导致复杂工况下荷电状态(state of charge, SOC)估计精度下降。针对上述问题,本文提出一种物理信息引导熵权自适应扩展卡尔曼滤波(physics-informed entropy-weighted adaptive extended Kalman filter, PI-EWAEKF)方法。首先,基于准静态标定结果构建开路电压(open-circuit voltage, OCV)-SOC与表面力-SOC物理映射关系;其次,采用增量力分析(incremental force analysis, IFA)提取抗漂移力学特征,并结合OCV梯度构建多源物理特征集;进一步,利用香农熵和物理梯度共同表征电压与表面力信号的实时置信度,并将其映射为AEKF测量噪声协方差矩阵的自适应调节因子,从而实现多源观测权重的动态分配。实验在25℃、35℃、45℃以及健康状态约为100%和91%条件下开展,并采用联邦城市行驶工况(federal urban driving schedule, FUDS)、动态应力测试(dynamic stress test, DST)和新欧洲行驶工况(new European driving cycle, NEDC)进行验证。结果表明,相较于单电压观测模型,所提方法在25℃动态工况下将FUDS、DST和NEDC工况的均方根误差分别由4.13%、3.70%和4.10%降低至0.96%、0.97%和0.79%,最大降幅约为80.7%。在高温与老化耦合条件下,所提方法仍能保持较低误差水平,验证了其在复杂工况下的估计精度与鲁棒性。

关键词: 磷酸铁锂电池; 荷电状态估计; 物理信息引导; 多源信息融合; 香农熵; 熵权自适应扩展卡尔曼滤波

doi: 10.19799/j.cnki.2095-4239.2026.0420

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-15

Physics-Informed Adaptive Filtering Method for State-of-Charge Estimation of Lithium Iron Phosphate Batteries

Luo Ke¹, Qiang Dong¹, Weng Wei¹, Yao Rong¹, Fu Juncheng², Zhang Xuanming³, Meng Jinhao³

(¹TBEA Xinjiang New Energy Co., Ltd., Urumqi 830011, Xinjiang Uygur Autonomous Region, China; ²National Innovation Platform (Center) for Industry-Education Integration of Energy Storage Technology, Xi'an Jiaotong University, Xi'an 710049, Shaanxi, China; ³School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, Shaanxi, China)

Abstract: Lithium iron phosphate (LFP) batteries are widely used in electric vehicles and energy storage systems. However, their weak observability in the voltage plateau region, together with the coupled effects of temperature drift, mechanical hysteresis, and aging on

收稿日期: 2026-05-15; 修改稿日期: 2026-06-12。

基金项目: 工信部制造业高质量发展专项(gx23225)。

第一作者: 骆可(1985—),男,学士,中级工程师,研究方向为储能系统集成与运行优化, E-mail: luoke@tbea.com; 通信作者: 孟锦豪,副教授,研究方向为储能系统设计与能量管理、电池建模与SOX估计、数据-机理混合的大数据电池诊断预警、电池系统测试方法与性能评价, E-mail: jinhao@xjtu.edu.cn。

引用本文: 骆可,强栋,翁伟,等.基于物理信息引导的磷酸铁锂电池荷电状态估计方法[J].储能科学与技术,XXXX,XX(XX): 1-15.

Citation: Luo Ke, Qiang Dong, Weng Wei, et al. Physics-Informed Adaptive Filtering Method for State-of-Charge Estimation of Lithium Iron Phosphate Batteries[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-15.

surface-force signals, reduces the accuracy of state of charge (SOC) estimation under complex operating conditions. To address these issues, this paper proposes a physics-informed entropy-weighted adaptive extended Kalman filter (PI-EWAEKF) method. First, the physical mapping relationships of open-circuit voltage (OCV)-SOC and surface force-SOC are established based on quasi-static calibration results. Second, incremental force analysis is used to extract drift-resistant mechanical features, which are combined with OCV gradients to construct a multi-source physical feature set. Furthermore, Shannon entropy and physical gradients are jointly used to characterize the real-time confidence of voltage and surface-force signals, which is then mapped into adaptive adjustment factors for the measurement noise covariance matrix of the adaptive extended Kalman filter (AEKF), thereby enabling dynamic allocation of multi-source observation weights. Experiments are conducted at 25 °C, 35 °C, and 45 °C under state of health levels of approximately 100% and 91%, and are validated using the federal urban driving schedule (FUDS), dynamic stress test (DST), and new European driving cycle (NEDC). The results show that, compared with a voltage-only observation model, the proposed method reduces the root mean square errors under FUDS, DST, and NEDC profiles at 25 °C from 4.13%, 3.70%, and 4.10% to 0.96%, 0.97%, and 0.79%, respectively, with a maximum reduction of approximately 80.7%. Under coupled high-temperature and aging conditions, the proposed method still maintains low error levels, demonstrating its estimation accuracy and robustness under complex operating conditions.

Keywords: lithium iron phosphate battery; state of charge estimation; physics-informed guidance; multi-source information fusion; Shannon entropy; entropy-weighted adaptive extended Kalman filter

锂离子电池 (lithium-ion batteries, LIBs) 凭借高功率密度、低自放电率、无记忆效应等显著优势, 已成为电池储能系统 (battery energy storage system, BESS) 与电动汽车 (electric vehicle, EV) 的核心储能单元^[1]。在该领域中, 磷酸铁锂 (lithium iron phosphate, LFP) 电池因热稳定性优异、循环寿命长、成本效益高, 市场份额快速提升, 现已成为大型储能与动力应用的首选技术方案^[2]。然而, LFP 电池的安全运行与高效利用高度依赖先进的电池管理系统 (battery management system, BMS), 其中荷电状态 (state of charge, SOC) 估计是 BMS 的核心技术。精准的 SOC 估计可有效避免电池过充、过放, 防止发生不可逆的内部损伤^[3]; 同时, 还能为电池均衡与剩余使用寿命预测提供可靠的数据支撑^[4]。

现有 SOC 估计方法大体可分为数据驱动方法和模型驱动方法^[5]。数据驱动方法将电池视为黑箱, 不依赖复杂的电化学模型或等效电路模型, 而是通过学习电压、电流等运行数据之间的非线性映射关

系实现估计^[6]。这类方法可进一步分为传统机器学习 (machine learning, ML) 与深度学习 (deep learning, DL) 方法。传统机器学习方法包括支持向量回归 (support vector regression, SVR)^[7]、随机森林 (random forest, RF)^[8]和反向传播神经网络 (backpropagation neural network, BPNN)^[9]。例如, Tian 等人^[10]提出一种多模式集成 SVR, 通过对电池数据聚类并构建 SVR 子模型, 对输出加权融合以提升估计精度、泛化能力与稳定性。尽管传统机器学习方法计算速度快、精度较高, 但其泛化能力有限, 难以适应电池老化、极端温度及复杂工况。深度学习方法包括循环神经网络 (recurrent neural network, RNN)^[11]、长短期记忆网络 (long short-term memory, LSTM)^[12]、门控循环单元 (gated recurrent unit, GRU)^[13]、卷积神经网络 (convolutional neural network, CNN)^[14]等典型结构。深度学习方法计算精度与泛化能力较强^[15], 但计算耗时较长, 难以满足储能系统、电动汽车等场景下 SOC 实时估计的需求^[16]。

与数据驱动方法相比，基于模型的方法因计算效率高、物理可解释性强，在实际工程中应用更为广泛^[16]。这类方法通常以等效电路模型（equivalent circuit model, ECM）或电化学模型为基础，结合闭环滤波算法或状态观测器，实现SOC在线估计与误差修正。典型的观测器方法包括滑模观测器^[17]、龙伯格观测器^[18]以及扩张状态观测器^[19]。这类方法理论稳定性较强，但抗噪声能力较弱，且高度依赖模型精度，难以通过自适应机制完全补偿。相比之下，基于卡尔曼滤波的方法在噪声抑制与不确定性处理方面更具优势。例如，Wu等人[20]构建了温度补偿的戴维南等效电路模型，并采用无迹卡尔曼滤波（unscented Kalman filter, UKF）进行SOC估计，将最大估计误差控制在3%以内。近年来，大量研究通过自适应算法提升滤波鲁棒性。Wang等人[21]引入动态矩阵控制优化扩展卡尔曼滤波（extended Kalman filter, EKF），将OCV辨识偏差与SOC估计误差分别控制在10mV和5%以内。

然而，上述基于模型的滤波方法在应用于磷酸铁锂电池时仍面临诸多挑战^[22]。LFP电池在20% - 80%的宽SOC区间内呈现出极其平坦的开路电压曲线，SOC每变化1%，电压通常仅变化几毫伏^[23]。这种近乎为零的斜率极易被测量噪声与传感器误差淹没，仅依靠电信号会严重降低状态可观测性。为克服这一缺陷，近年来研究者引入表面膨胀力作为额外感知维度，后续简称表面力。Jiang等人[24]引入堆叠力以解决电压平台问题，但该方法需针对不同电池类型重新配置模型。此外，表面力信号与电信号的融合通常依赖人工设定权重，泛化能力有限。值得注意的是，表面力不仅受锂离子嵌入/脱嵌引起的本征应变影响，还与热膨胀效应强耦合，在复杂变温工况下会出现非线性漂移与机械滞后。Xiong等人[25]采用归一化方法抑制表面力信号漂移，但该方法依赖离线标定与初始测量，难以实现实时自适应应用。现有多源方法普遍缺乏有效的在线解耦机制以消除表面力信号中的热干扰，也无法自适应评估不同感知模态的可靠性，只能采用静态或经验融合规则。因此，实现机电多源数据高效自适应协同融合，仍是LFP电池鲁棒SOC估计的核心难题。

为实现磷酸铁锂电池的鲁棒荷电状态估计，本

文提出一种物理信息引导熵权自适应扩展卡尔曼滤波（physics-informed entropy-weighted adaptive extended Kalman filter, PI-EWAEKF）方法。在该框架下，通过香农熵对增量物理特征的信号置信度进行量化，构建鲁棒的多源信号优化策略，并将其作为先验物理约束输入熵权自适应扩展卡尔曼滤波（entropy-weighted adaptive extended Kalman filter, EWAEKF），引导滤波器在在线迭代中自适应重构测量噪声协方差矩阵。本文的主要贡献总结如下：

（1）构建了一种基于香农熵与增量物理特征的多源信号优化策略。针对表面力信号的热-力耦合畸变问题，采用增量力分析进行解耦提取，获得对温度变化与老化不敏感的本征特征，并通过香农熵动态量化各物理参数的信号置信度。

（2）提出了一种物理信息先验驱动的EWAEKF算法。创新性地将多源物理特征的梯度信号转化为信号置信度系数，引导滤波器在线自适应重构测量噪声协方差矩阵。

（3）在宽温度范围（25℃-45℃）及不同健康状态（100%与91%）下进一步验证了所提方法的有效性，并在所有工况组合下采用动态应力测试（dynamic stress test, DST）、联邦城市行驶工况（Federal Urban Driving Schedule, FUDS）及新欧洲行驶工况（New European Driving Cycle, NEDC）进行验证。

1 电池测试与特性分析

1.1 实验设置

本研究采用湖北亿纬动力有限公司生产的LF32型铝壳方形磷酸铁锂电池作为实验样品。该电池正极材料为磷酸铁锂（ LiFePO_4 ），负极材料为石墨，额定容量32.0 Ah，额定电压3.2 V，充电截止电压为3.65 V，放电截止电压为2.5 V，最大连续充放电电流为1 C，该参数与车载及储能场景的实际工作特性相匹配^[26]。为验证方法在不同老化阶段的适应性，本文选取全新电池A01组（SOH≈100%）和循环老化电池B01组（SOH≈91%）作为测试样品。

本文搭建了如图1所示的多参数协同测试平台，用于精准获取电池电-热-力多维参数。电池充放电行为由新威BTSCClient80电池测试系统精确控

制；实验环境温度由高精度恒温箱调节，控温精度为 $\pm 2^{\circ}\text{C}$ ，并设置 25°C 、 35°C 、 45°C 三档温度。被测电池被夹紧在由两块高强度钢板组成的测试夹具中心；在电池最大表面的中心位置安装薄膜压力传感器（量程 $0 \sim 3\text{t}$ ，精度 $\pm 0.05\%\text{FS}$ ），实时监测由锂离子嵌入/脱嵌引起的表面力变化。测试前，通过调节夹具四角螺母对电池施加均匀初始预紧力，消除机械间隙对力测量的干扰，本研究将预紧力统一设定为 200N 。实验过程中，上位机同步采集电压、电流与表面力信号，采样频率设置为 1Hz 。



图1 实验平台结构示意图

Fig. 1 Schematic diagram of the experimental platform

详细测试流程设计如下：对A01组与B01组样品分别开展三组实验，实验环境温度设置为 25°C 、 35°C 、 45°C ，用于构建多维特征数据集并验证算法性能。

(1) 准静态机电特性标定实验：采用 0.01C 小电流充放电制度，获取各温度与老化状态下的电压、表面力参考特性曲线。每次完整充电或放电结束后，电池均静置 4h ，以保证端电压充分趋于稳定。同一SOC点下的充电电压与放电电压平均值作为该SOC点对应的OCV，最终通过函数拟合获得后续滤波观测方程中使用的OCV-SOC映射关系。不同温度和老化状态下的OCV-SOC标定曲线见附录图A.1。

(2) 动态工况验证实验：依次开展DST、FUDS、NEDC等典型变负载工况，以模拟实际运行场景。

实验全程参考SOC基于测试系统直接记录的充放电容量实时计算，最大可用容量在对应温度与

老化状态下定期标定。

1.2 电与机械特性分析

电池在 25°C 下的准静态机电标定实验结果如图2所示。可以看出，LFP电池的OCV曲线在 $5\% \sim 98\%$ SOC范围内呈现出明显平台特性。在该区间内，OCV仅由 3.211V 上升至 3.379V ，平均梯度约为 $1.8\text{mV}/1\%\text{SOC}$ ，说明电压信号对SOC的灵敏度较弱。与之形成鲜明对比的是，表面力呈现出清晰的非单调变化特性，极大弥补了电信号的观测盲区。这种现象主要来源于受约束边界条件下，LFP正极与石墨负极在嵌锂/脱锂过程中体积变化的耦合作用。He等人[27]在磷酸铁锂/碳（lithium iron phosphate/carbon, LFP/C）电池研究中发现了典型的鞍形非单调应力特性曲线，并指出该现象源于LFP正极与石墨负极应力贡献的叠加效应。表面力的演化可分为三个明显阶段：初始膨胀阶段（ $0\% \sim 29\%$ SOC）、中期收缩阶段（ $29\% \sim 60\%$ SOC）以及后期再膨胀阶段（ $60\% \sim 100\%$ SOC）。值得注意的是，在OCV平台区内，表面力信号具有显著可区分的变化。例如，在锂离子嵌入引发的膨胀与晶格重排的共同作用下，表面力从SOC $\approx 29\%$ 时的约 200N 大幅下降至SOC $\approx 60\%$ 时的 150N 。然而，在表面力-SOC斜率趋近于零或发生反转的区域，仅依靠表面力信号同样会导致严重的估计误差。因此，OCV与表面力信号具有极强的观测互补性。




图2 25°C 下电池准静态电-表面力特性曲线

Fig. 2 Quasi-static voltage and surface-force characteristics versus SOC at 25°C

为评估高频动态负载与多环境因素在真实车辆运行场景下对多物理场耦合特性的综合影响，图3给出了端电压与表面力的对比结果。实验采用相同的变负载激励（DST、FUDS、NEDC工况），分组设置不同环境温度（ 25°C 、 35°C 、 45°C ，全新电

池)与多种老化状态进行测试。




图3 动态工况下电压与表面力响应结果

Fig. 3 Dynamic operating condition experiment results

由图3(d) - (f)的电压响应可知,在充放电电流剧烈波动的情况下,端电压主要受内阻欧姆压降与极化内阻共同影响,呈现出剧烈的高频振荡,大幅提升了电压平台区内状态估计的难度。虽然环境温度升高(35℃、45℃)会降低电池内部阻抗,使电压波动范围略有收窄,而电池老化会加剧放电末期的电压跌落,但在多重干扰下,电压的宏观变化边界与基本平台特性仍保持相对稳定。然而,图3(g) - (i)揭示了表面力信号在复杂工况下的脆弱性。热膨胀会引发显著的基线漂移。例如,在FUDS工况下,当环境温度从25℃升至45℃时,初始绝对表面力大幅上升近100 N(从约280N增至380 N)。此外,老化电池内部发生不可逆结构退化,会使表面力学响应曲线完全畸变,不仅出现明显的基线向下偏移(起始点约240 N),还会丧失原有的非单调特征形态,在整个循环中趋于平坦。

尽管表面力信号能够弥补电压平台区内SOC可观测性不足的问题,但其绝对值会受到极化、机械滞后与温度漂移的强耦合干扰。因此,直接引入这类信号无法提供有效的观测贡献,反而可能导致

估计模型发散。为此,本文第2章引入增量力分析(incremental force analysis, IFA)与香农信息熵理论,旨在提取对环境与老化不敏感的相变特征分量,并将其作为物理先验,构建多源信号动态优化策略,最终实现全工况下多参数信息的鲁棒协同。

2 提出的方法

2.1 所提框架

本文所提出的PI-EWAEKF框架如图4所示,该框架包含四个核心模块。首先,构建系统输入层,由在线实时测量数据与离线预标定基准数据两部分组成。从电池测试系统中同步实时采集电流 I 、电压 U 、表面力 F_p 等多维动态信号;同时,将通过三种温度工况、两种老化状态下准静态实验离线标定得到的开路电压-荷电状态(OCV-SOC)、表面力-SOC映射曲线嵌入系统,作为后续算法查表所用的基础物理基准。其次,开展参数辨识。搭建二阶RC等效电路模型,基于实测电压 U 与电流 I 信号,采用递归最小二乘法(recursive least squares, RLS)对电路参数进行在线辨识,持续更新模型参数向量,为状态观测提供支撑。再次,

在熵权模块中，同步提取 dU_{oc}/dQ 、 dF_q/dQ 多源梯度特征。引入香农信息熵理论，定量评估梯度信号在噪声干扰下的动态不确定性；将计算得到的熵值转化为物理先验信息，实现测量噪声协方差矩阵 R 的自适应更新。该机制可动态评判信号置信度，降低无序度高的信号权重。最后，由自适应扩展卡尔

曼滤波 (adaptive extended Kalman filter, AEKF) 模块完成估计运算。依托实时更新的模型参数与重构后的协方差矩阵 R ，滤波器依次完成先验更新、引入增广观测方程及后验更新过程。通过动态分配多源观测权重并修正传感器偏差，最终输出鲁棒的 SOC 估计结果。




图4 PI-EWAEKF 方法框架流程图

Fig. 4 Flowchart of the proposed PI-EWAEKF method for SOC estimation

2.2 多源增量特征提取

在电池健康状态评估领域，增量容量分析 (incremental capacity analysis, ICA) 已被广泛证实能够有效揭示电池内部的电化学反应过程与老化机理[28]。针对宏观表面力绝对值易受温度漂移、机械边界和老化状态影响而出现基线偏移与映射畸变的问题，本文借鉴 ICA 的核心思想，引入增量力分析 (incremental force analysis, IFA) 以提取与容量变化相关的力学增量特征。与直接使用表面力绝对值不同，IFA 通过计算表面力随容量变化的增量梯度，能够削弱低频基线漂移和绝对幅值偏移的影响，从而突出与 SOC 变化和电极相变过程相关的阶段性力学响应。

在实际在线应用场景中，当前时刻的真实 SOC 为未知量，因此采用安时积分得到的容量变化作为微分变量。表面力增量梯度和 OCV 梯度可表示为：

$$\left(\frac{dF_q}{dQ}\right)_t \approx \frac{F_q(t) - F_q(t - \Delta t)}{\int_{t-\Delta t}^t \eta I(\tau) d\tau} \quad (1)$$

$$\left(\frac{dU_{oc}}{dQ}\right)_t \approx \frac{U_{oc}(t) - U_{oc}(t - \Delta t)}{\int_{t-\Delta t}^t \eta I(\tau) d\tau} \quad (2)$$

式中， $F_q(t)$ 与 $U_{oc}(t)$ 分别表示当前时刻 t 的实测表面力与开路电压。 Δt 为差分计算所采用的时间窗口；积分项代表该时间窗口内通过安时积分法累积的充放电容量，其中 η 为库伦效率。

为便于后续滑动窗口统计与滤波迭代，本文将上述连续时间梯度在第 k 个采样时刻的离散值记为：

$$g_F^{(k)} = \left(\frac{dF_q}{dQ}\right)_k, g_U^{(k)} = \left(\frac{dU_{oc}}{dQ}\right)_k \quad (3)$$

其中， $g_F^{(k)}$ 和 $g_U^{(k)}$ 分别表示第 k 个采样时刻的表面力梯度和 OCV 梯度。上述增量梯度用于表征表面力和电压信号对容量变化的局部响应能力，后续将结合滑动窗口熵值计算，用于评价不同观测通道

的实时可靠性。

2.3 信号优选策略

实际BMS中的梯度信号由真实物理响应与测量噪声共同构成。当电压或表面力信号在某一区间内对SOC变化不敏感时，微分运算会放大噪声，导致梯度序列呈现高度离散的无序分布。在信息论中，香农熵是量化信号信噪比分布与数据不确定性的理想数学工具^[29]。因此，香农熵可用于衡量信号分布的不确定性：熵值越大，说明数据分布越分散、无序程度越高，观测置信度越低；熵值越小，说明数据分布更集中，物理响应更稳定。

考虑到在线估计的因果性与时效性，本文采用基于固定长度滑动时间窗口的统计评估机制。在系统初始启动阶段，算法依靠初始化的先验测量噪声协方差完成基础滤波，同时数据累积窗口随采样时间动态扩容；当累积时长达到预设规模后，算法自动切换为固定长度滑动时间窗口。该窗口内熵值及信号置信度系数的具体量化步骤如下：

(1) 极值锁定与区间划分

在当前滑动窗口内，提取长度均为 L 的实测电压梯度序列 $g_U^{(k)}$ 与力学梯度序列 $g_F^{(k)}$ 。分别锁定两个序列在该窗口内的最大值与最小值，并将其等划分为 n 个子区间。两个子区间的步长分别设为 $w_U^{(k)}$ 与 $w_F^{(k)}$ ，可通过下述公式计算：

$$w_U^{(k)} = \frac{\max(g_U^{(k)}) - \min(g_U^{(k)})}{n} \quad (4)$$

$$w_F^{(k)} = \frac{\max(g_F^{(k)}) - \min(g_F^{(k)})}{n} \quad (5)$$

(2) 概率分布映射

统计实测梯度数据落入各子区间的频次。设 $N_{U,i}^{(k)}$ 和 $N_{F,i}^{(k)}$ 分别为OCV梯度和表面力梯度落入第 i 个子区间的样本数，则对应概率可表示为：

$$p_{U,i}^{(k)} = \frac{N_{U,i}^{(k)}}{L} \quad (6)$$

$$p_{F,i}^{(k)} = \frac{N_{F,i}^{(k)}}{L} \quad (7)$$

其中， $i=1,2,\dots,n$ 。

(3) 动态熵计算

根据香农熵定义，OCV梯度和表面力梯度在当前滑动窗口内的信息熵分别为：

$$H_U^{(k)} = -\sum_{i=1}^n p_{U,i}^{(k)} \log(p_{U,i}^{(k)}) \quad (8)$$

$$H_F^{(k)} = -\sum_{i=1}^n p_{F,i}^{(k)} \log(p_{F,i}^{(k)}) \quad (9)$$

其中，根据信息论中的通用计算惯例，当 $p=0$ 时，规定 $p \log(p) = 0$ 。 $H_U^{(k)}$ 和 $H_F^{(k)}$ 分别用于描述电压梯度和表面力梯度在当前窗口内的无序程度。熵值越大，说明对应通道的梯度分布越分散，观测可靠性越低。

由于香农熵的最大值与区间数 n 有关，本文进一步计算归一化熵： $\bar{H}_U^{(k)} = H_U^{(k)} / \ln n$ ， $\bar{H}_F^{(k)} = H_F^{(k)} / \ln n$ 。其中， $\bar{H}_U^{(k)}$ 和 $\bar{H}_F^{(k)}$ 的取值范围均为 $[0,1]$ 。归一化熵越大，说明该通道的梯度分布越无序，观测置信度越低。

(4) 置信度计算

将求得的电压梯度信号与表面力梯度信号的归一化后，将其映射在测量噪声矩阵中，具体计算公式如下：

$$C_U^{(k)} = \exp(-\lambda \bar{H}_U^{(k)}) S_U^{(k)} \quad (10)$$

$$C_F^{(k)} = \exp(-\lambda \bar{H}_F^{(k)}) S_F^{(k)} \quad (11)$$

其中 λ 是大于零的正则化系数，用于调节归一化熵对置信度的影响强度。 $S_U^{(k)}$ 和 $S_F^{(k)}$ 分别表示电压通道和表面力通道的梯度可观测性因子，计算方式如下：

$$S_U^{(k)} = \frac{|\bar{g}_U^{(k)}|}{|\bar{g}_U^{(k)}| + |\bar{g}_F^{(k)}| + \varepsilon} \quad (12)$$

$$S_F^{(k)} = \frac{|\bar{g}_F^{(k)}|}{|\bar{g}_U^{(k)}| + |\bar{g}_F^{(k)}| + \varepsilon} \quad (13)$$

其中， $\bar{g}_U^{(k)}$ 和 $\bar{g}_F^{(k)}$ 分别表示第 k 个采样时刻电压梯度和表面力梯度的归一化值， ε 是一个足够小的数。

上述定义表明，信号置信度由归一化熵和梯度可观测性因子共同决定。低熵值和高可观测性对应较高置信度，反之则降低置信度，从而实现电压和表面力通道观测权重的在线调节。

2.4 PI-EWAEKF自适应估计方法

为兼顾计算复杂度与模型精度，本文采用二阶RC等效电路模型，如图5所示。其中 U_t 为端电压， U_{oc} 为开路电压， R_0 为欧姆内阻， R_1 、 C_1 和 R_2 、 C_2 分别表示两个极化支路。

根据基尔霍夫定律，可推导出锂离子电池二阶RC等效电路模型的数学表达式如下：

$$I(t) = C_1 \frac{dU_1}{dt} + \frac{U_1}{R_1} = C_2 \frac{dU_2}{dt} + \frac{U_2}{R_2} \quad (14)$$




图5 二阶 RC 等效电路模型

Fig. 5 Second-order RC equivalent circuit model

$$U_t = U_{OC} - U_1 - U_2 - R_0 I(t) \quad (15)$$

为构建观测方程的无噪声理论基准, 本文利用准静态实验离线标定得到的 OCV-SOC 与表面力-SOC 映射多项式, 将动态预测的 SOC 映射为理想开路电压 U_{OC} 与理想膨胀力 F_p 。

为保证模型在复杂工况下具有高保真度, 本文首先采用 RLS 对电路参数进行在线辨识, 并实时更新参数向量 θ_k 。随后通过物理反解得到 R_0 , R_1 , C_1 , R_2 , C_2 等实际电路参数。其中 T 为测量时间间隔。通过该方式, 电池模型参数可随环境及其他影响因素实现动态变化。25℃ 典型 FUDS 工况下二阶 RC 模型参数的递归最小二乘辨识结果见附录图 A.2。

正如 2.2 节中动态工况试验所揭示, 电池表面力极易受机械滞后、塑性形变及热膨胀效应影响, 致使电池在持续工作过程中出现低频非线性基线漂移。为动态追踪该类偏差并实现电压-表面力信号的鲁棒协同估计, 本文采用状态增广策略。将缓变的力学基线偏差建模为随机游走过程: $F_{ew,k} = F_{ew,k-1} + w_{ew,k-1}$ 并将其与基础电气状态融合, 构建增广状态向量: $x_k = [U_{1,k}, U_{2,k}, SOC_k, F_{ew,k}]^T$ 系统对应的增广观测方程如下所示:

$$z_k = \begin{bmatrix} U_{t,k} \\ F_{q,k} \end{bmatrix} = \begin{bmatrix} U_{OC}(SOC_k) - U_{1,k} - U_{2,k} - R_0 I_k \\ F_p(SOC_k) + F_{ew,k} \end{bmatrix} + v_k \quad (16)$$

其中, $U_{t,k}$ 和 $F_{q,k}$ 分别表示第 k 时刻实时测量的电池端电压与外部表面力; $U_{OC}(SOC_k)$ 和 $F_p(SOC_k)$ 分别为离线标定得到的理想本征电压与力学映射曲线; v_k 代表多源测量噪声。

将 F_{ew} 扩维至状态向量, 是建立针对力学信号缓变漂移的随机游走模型。在滤波迭代过程中, 无需引入额外的力学状态方程, F_{ew} 的更新即可直接通过多源观测残差与卡尔曼增益的交叉耦合实现闭环在线标定, 进而在电压平台区为系统提供高置信

度的力学先验信息。

在建立上述状态转移矩阵与观测矩阵后, 本文引入熵权引导机制, 并将 2.3 节计算得到的熵值直接映射为先验信号置信度系数。滤波迭代过程中, EWAEKF 算法利用该物理先验, 自适应在线重构测量噪声协方差矩阵。该机制不仅能够实现融合权重的动态分配, 还可结合增广状态实现传感器基线偏差的在线补偿, 最终输出鲁棒性极强的 SOC 估计结果。详细算法推导详见附录 A (表 A.1)。算法中的超参数选取及其依据详见附录 A (表 A.2)。

3 结果与讨论

为全面验证所提 PI-EWAEKF 方法的有效性与泛化能力, 基于前述多参数协同测试平台开展系统实验验证。实验验证主要包括以下几个方面: 首先, 在 25℃ 条件下验证多源观测模型在典型动态工况下的 SOC 跟踪能力; 其次, 在 35℃ 与 45℃ 条件下分析宽温度范围内模型对热-力耦合干扰的鲁棒性; 最后, 在不同老化状态下验证模型对长期参数漂移与力信号退化的适应能力。

为定量评价不同方法的 SOC 估计性能, 本文采用绝对误差、平均绝对误差和均方根误差作为评价指标。设第 k 个采样点的真实 SOC 为 $SOC_{ref}(k)$, 估计 SOC 为 $SOC_{est}(k)$, 测试样本总数为 N , 则绝对误差可表示为:

$$AE(k) = |SOC_{est}(k) - SOC_{ref}(k)| \quad (17)$$

平均绝对误差可表示为:

$$MAE = \frac{1}{N} \sum_{k=1}^N AE_k \quad (18)$$

均方根误差可表示为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N AE_k^2} \quad (19)$$

其中, AE 用于表征 SOC 估计结果在每个采样时刻相对于真实值的偏离程度; MAE 反映整个测试过程中的平均估计偏差; $RMSE$ 对较大误差更加敏感, 可用于评价模型在复杂动态工况下的稳定性和鲁棒性。上述指标越小, 说明模型的 SOC 估计精度越高。

3.1 动态工况下的多源观测与 SOC 跟踪性能分析

本节实验均在 25℃ 环境温度下进行, 测试电池 SOH 约为 100%。为模拟车辆及储能系统中的复杂动态负载工况, 分别采用 FUDS、DST 与 NEDC

三种典型动态工况对电池进行测试。为分析表面力信号与物理信息引导策略对 SOC 估计性能的影响，在相同滤波框架下建立两种不同观测模型。其中，“无表面力”模型仅采用端电压作为观测量；“有表面力”模型同时引入端电压与表面力信号，并利用增量物理特征与香农熵实现观测权重的动态调节。图 6 给出了不同动态工况下两种模型的 SOC 估计结果与绝对误差变化情况。




图 6 动态工况下有无表面力输入模型的 SOC 估计轨迹与绝对误差曲线 (a) FUDS 工况; (b) DST 工况; (c) NEDC 工况

Fig. 6 SOC estimation trajectories and absolute error curves of models with and without surface-force input under dynamic operating conditions. (a) FUDS profile; (b) DST profile; (c) NEDC profile.

由图 6(a)可以看出，在 FUDS 工况下，无表面力模型在放电初始阶段具有一定跟踪能力，但随着 SOC 进入 LFP 电池典型电压平台区，其估计轨迹逐渐偏离参考值。这是由于 LFP 电池在宽 SOC 区间内 OCV 梯度较低，仅依赖电压信号时系统可

观测性显著下降。对应误差曲线显示，无表面力模型在平台区出现持续偏移，其 RMSE 达到 5.11%。相比之下，PI-EWAEKF 通过引入增量表面力特征，对平台区缺失的电压可观测性进行了有效补偿。同时，基于香农熵构建的物理置信度评价机制能够实时评估不同观测通道的可靠性，并动态调整测量噪声协方差矩阵，从而抑制局部失真信号对滤波结果的干扰。因此，PI-EWAEKF 的 SOC 估计轨迹能够持续贴合参考值，其 RMSE 降低至 0.96%。

从图 6(b)与图 6(c)可以进一步发现，在 DST 与 NEDC 等更复杂动态工况下，无表面力模型的估计偏差进一步扩大。其中，DST 工况下 RMSE 达到 4.16%，NEDC 工况下达到 3.62%。复杂动态电流激励会引起极化电压快速变化，进一步削弱平台区电压信号对 SOC 的辨识能力。相比之下，PI-EWAEKF 在不同动态工况下均保持稳定估计性能，DST 与 NEDC 工况下 RMSE 分别维持在 0.97% 与 0.70%。与单电压观测模型相比，NEDC 工况下 RMSE 降幅约为 80.7%。结果表明，多源物理特征能够显著增强平台区 SOC 可观测性，而熵权自适应观测策略能够有效避免局部失真观测对滤波结果造成误导。

为进一步区分不同模块对 SOC 估计性能的贡献，本文在 25℃、SOH≈100% 条件下选取 FUDS 工况进行模块级消融实验。构建四种对比模型：AEKF-U 表示仅采用端电压观测的自适应扩展卡尔曼滤波模型；AEKF-UF 表示同时采用端电压和原始表面力观测的模型，其中表面力通过准静态标定得到的表面力-SOC 映射关系直接进入观测方程；IFA-AEKF 表示在 AEKF-UF 基础上进一步引入增量力分析特征的模型；PI-EWAEKF 表示本文提出的完整模型，即同时引入表面力观测、IFA 特征和熵权自适应融合机制。表 1 给出了不同消融模型的模块构成和误差结果，其中“√”表示采用该模块，“—”表示未采用该模块。

由表 1 可知，AEKF-U 在 FUDS 工况下的 RMSE 和 MAE 分别为 5.11% 和 4.24%，说明仅依赖电压观测时，LFP 电池平台区 SOC 可观测性不足。AEKF-UF 引入原始表面力观测后，RMSE 降低至 2.74%，表明表面力信号能够为平台区 SOC 估计提供额外观测信息。进一步引入 IFA 特征后，IFA-AEKF 的 RMSE 降低至 1.56%，说明增量力特

表 1 PI-EWAEKF 方法在 FUDS 工况下的模块级消融实验结果

Table 1 Module-level ablation results of the PI-EWAEKF method under the FUDS profile.


方法	表面力观测	IFA 特征	熵权自适应机制	RMSE / %	MAE / %
AEKF-U	—	—	—	5.11	4.24
AEKF-UF	√	—	—	2.74	2.05
IFA-AEKF	√	√	—	1.56	1.14
PI-EWAEKF	√	√	√	0.96	0.73

征有助于削弱原始表面力绝对值中的基线漂移和幅值偏移影响。完整 PI-EWAEKF 进一步结合熵权自适应机制,使 RMSE 和 MAE 分别降低至 0.96% 和 0.73%,表明该机制能够根据观测可靠性动态调整电压和表面力通道权重,从而进一步提高 SOC 估计稳定性。上述结果说明,PI-EWAEKF 的性能提升并非来源于单一模块,而是由表面力观测补充、IFA 特征提取和熵权自适应融合共同作用形成。其中,表面力观测主要补充 LFP 电压平台区的观测信息,IFA 特征主要增强表面力信号中与 SOC 变化相关的有效力学信息,熵权自适应机制则进一步实现不同观测通道权重的在线调节。

4.2 宽温度范围下 SOC 估计鲁棒性分析

为进一步分析温度变化与热-力耦合对 SOC 估计性能的影响,在 35℃ 与 45℃ 条件下继续开展动态工况实验。图 7 给出了不同温度与工况组合下两种模型的 RMSE 与 MAE 对比结果。

由图 7(a)与图 7(b)可以看出,随着环境温度升高,无表面力模型的误差边界明显扩大。以 35℃ NEDC 工况为例,高温环境下电池极化特性发生变化,使电压平台区的可观测性进一步下降,其 RMSE 与 MAE 分别上升至约 0.0551 与 0.0470。与此同时,高温会增强电池表面热膨胀效应,引起绝对表面力信号出现明显基线漂移。若直接利用原始表面力信号进行状态估计,容易导致力学观测失真,甚至引发滤波估计偏移。相比之下,PI-EWAEKF 通过增量力分析提取抗漂移物理特征,并结合香农熵实时评估观测通道置信度,实现了表面力信号权重的动态调节。当表面力信号受热漂移影响而置信度降低时,滤波器会自动降低该观测通道权重;当电压平台区电压梯度减小时,则增强表面力观测贡献。因此,所提方法在宽温度范围内仍保持较好的估计稳定性。



(a) Radar chart of RMSE; (b) radar chart of MAE.

图 7 宽温度范围下不同模型 SOC 估计鲁棒性对比 (a) RMSE 雷达图; (b) MAE 雷达图

Fig. 7 Robustness comparison of SOC estimation errors of different models over a wide temperature range.

从图 7 可以进一步看出,在 45℃ NEDC 工况下,PI-EWAEKF 的 RMSE 与 MAE 分别为 0.0097 与 0.0093;在 35℃ DST 工况下,其 RMSE 与 MAE 分别为 0.0097 与 0.0076。相比无表面力模型,所提方法在各温度和动态工况下均表现出更低的估计误差。结果说明,基于物理信息引导的熵权自适应融合策略能够有效抑制温度变化和热-力耦合干扰,提高复杂环境下 SOC 估计的稳定性与鲁棒性。

3.3 不同老化状态下的估计性能验证

为验证模型在长期循环老化条件下的适应能力,进一步选取 SOH 约为 91% 的老化电池开展

实验。图 8 给出了不同温度与动态工况下 PI-EWAEKF 在老化电池上的误差统计结果。




图 8 老化电池在不同温度与工况下的 SOC 估计误差分布 (a) 绝对误差分布; (b) RMSE 热力图; (c) MAE 热力图
Fig. 8 SOC estimation error distribution of aged batteries under different temperatures and operating conditions. (a) Absolute error distribution; (b) heat map of RMSE; (c) heat map of MAE.

由图 8(a)可以看出, 在老化电池的不同温度与工况组合下, PI-EWAEKF 的绝对误差分布整体较为集中, 未出现明显发散。各工况下中位误差均维持在约 0.015 以内, 说明该方法在老化条件下仍具有较好的估计稳定性。进一步分析图 8(b)与图 8(c)中的 RMSE 与 MAE 可知, 即使在高温与老化耦合条件下, PI-EWAEKF 仍保持较高估计精度。其中, 在 45°C 条件下, DST、FUDS 与 NEDC 工况对应的 RMSE 分别为 0.0161、0.0166 与 0.0150; 对应 MAE 分别为 0.0141、0.0163 与 0.0130。上述结果表明, PI-EWAEKF 不仅能够抑制电压平台区引起的可观性下降, 还能够有效应对长期循环导致的电-力特性漂移问题。基于增量物理特征与熵权自适应融合的观测机制, 使模型在复杂工况、宽温度范围以及不同老化状态下均具有较强鲁棒性与工程适用性。

4 结 论

本文针对 LFP 电池电压平台区 SOC 可观性弱以及表面力信号易受温度漂移、机械滞后和老化效应影响的问题, 提出了一种物理信息引导熵权自适应扩展卡尔曼滤波方法。与直接融合原始电压和表面力信号不同, 所提方法的核心优势在于构建了面向多源观测可靠性的动态抗干扰融合机制。通过引入增量力分析和香农熵, PI-EWAEKF 能够从原始表面力信号中提取更稳定的力学增量特征, 并将电压梯度、力学梯度及其不确定性转化为实时信号置信度, 从而引导测量噪声协方差矩阵在线自适应更新。

系统实验结果表明, 原始绝对表面力信号容易受到动态极化、机械滞后、热膨胀和老化漂移的共同影响, 直接融合可能削弱 SOC 估计稳定性。所提 PI-EWAEKF 通过物理特征提取和熵权自适应调

节,有效抑制了热-力耦合干扰对观测信号的影响。当电池处于电压平台区时,模型能够增强表面力观测贡献;当表面力信号受温度或老化影响而置信度降低时,模型能够自动降低其观测权重,从而避免单一失真信号造成估计偏移。

在 25℃ 动态工况下,PI-EWAEKF 将 FUDS、DST 和 NEDC 工况下的 RMSE 分别降低至 0.96%、0.97% 和 0.79%,相比单电压观测模型最大降幅约为 80.7%。在 35℃、45℃ 宽温度范围以及 SOH≈91% 的老化状态下,所提方法仍保持较低误差水平。其中,在 45℃ 老化条件下,DST、FUDS 和 NEDC 工况对应的 RMSE 分别为 0.0161、0.0166 和 0.0150。上述结果验证了 PI-EWAEKF 在复杂动态负载、宽温度范围和不同老化状态下的估计精度与鲁棒性。

需要指出的是,表面力信号在实际工程应用中仍会受到传感器安装位置、初始预紧力一致性、夹具刚度、长期机械松弛、传感器零点漂移以及车载振动冲击等因素的影响。此外,在车载电池系统和大规模储能系统中,引入表面力传感器还会增加结构设计复杂度与系统集成成本。本文主要在单体电池和实验夹具条件下验证了所提方法的有效性。然而,模组级部署、长期循环条件下的力学稳定性验证以及工程化传感器布置优化仍需进一步研究。下一步工作将重点围绕三个方面展开:一是将所提方法扩展至电池模组,分析多电芯受力不均和夹具边界条件变化对估计性能的影响;二是开展长期循环和温度循环实验,评估预紧力衰减、机械松弛和传感器漂移对表面力观测的影响;三是优化表面力传感器的布置数量和安装位置,以降低系统集成成本并提高工程适用性。

参考文献

- [1] 张磊. 锂离子电池储能电站的运行状态监测与评估[J]. 储能科学与技术, 2025, 14(09): 3538-3540. DOI: 10.19799/j. cnki. 2095-4239.2025.0536.
ZHANG L. Operation state monitoring and evaluation of lithium-ion battery energy storage power stations[J]. Energy Storage Science and Technology, 2025, 14(09): 3538-3540. DOI: 10.19799/j. cnki. 2095-4239.2025.0536.
- [2] 陈勇,王俊磊,王鹏,等. 锂离子电池早期剩余寿命预测方法综述[J]. 电池, 2026, 56(01): 222-230. DOI: 10.19535/j. 1001-1579.2026.01.035.
CHEN Y, WANG J L, WANG P, et al. Review of early remaining useful life prediction methods for lithium-ion batteries[J]. Battery Bimonthly, 2026, 56(01): 222-230. DOI: 10.19535/j. 1001-1579.2026.01.035.
- [3] YU K, LIU P, XU B, et al. Warning lithium-ion battery thermal runaway with 4-min relaxation voltage[J]. Applied Energy, 2025, 377: 124466. DOI: 10.1016/j. apenergy. 2024. 124466.
- [4] WANG T, YANG X, YANG F, et al. Expansion force distribution characteristics of prismatic LiFePO₄ batteries during thermal runaway caused by overheating[J]. Journal of Energy Storage, 2026, 152: 120514. DOI: 10.1016/j. est. 2026. 120514.
- [5] SHEN L, LI J, MENG L, et al. Transfer learning-based state of charge and state of health estimation for Li-ion batteries: a review [J]. IEEE Transactions on Transportation Electrification, 2024, 10: 1465-1481. DOI: 10.1109/TTE.2023.3293551.
- [6] FU J, SONG Z, MENG J, et al. AI-augmented electrochemical model for lithium-ion battery: recent advances and perspectives [J]. Journal of Energy Chemistry, 2026, 113: 1056-1080. DOI: 10.1016/j. jechem. 2025. 10. 008.
- [7] SHARMA S, GARG A, PANIGRAHI B K. Predicting state-of-charge using gradient-boosted SVR ensemble technique for lithium ion battery used in EVs[J]. IEEE Transactions on Transportation Electrification, 2024, 10: 4441-4454. DOI: 10.1109/TTE.2023.3310159.
- [8] 刘素贞,袁路航,张闯,等. 基于超声时域特征及随机森林的磷酸铁锂电池荷电状态估计[J]. 电工技术学报, 2022, 37(22): 5872-5885.
LIU S Z, YUAN L H, ZHANG C, et al. State of charge estimation of lithium iron phosphate batteries based on ultrasonic time-domain features and random forest[J]. Transactions of China Electrotechnical Society, 2022, 37(22): 5872-5885.
- [9] 田佳强,张泽培,潘天红,等. 基于动量反向传播神经网络的锂离子电池建模与荷电状态估计[J]. 电工技术学报, 2025, 40(24): 8156-8170.
TIAN J Q, ZHANG Z P, PAN T H, et al. Lithium-ion battery modeling and state of charge estimation based on momentum backpropagation neural network[J]. Transactions of China Electrotechnical Society, 2025, 40(24): 8156-8170.
- [10] TIAN H, LI A, LI X. SOC estimation of lithium-ion batteries for electric vehicles based on multimode ensemble SVR[J]. Journal of Power Electronics, 2021, 21: 1365-1373. DOI: 10.1007/s43236-021-00279-9.
- [11] 窦元运,张成知,封居强. 多因素影响下融合 RNN 和 AUKF 的矿用锂离子电池 SOC 估计[J]. 电源技术, 2025, 49(04): 764-771.
DOU Y Y, ZHANG C Z, FENG J Q. SOC estimation of mine-used lithium-ion batteries integrating RNN and AUKF under multi-factor influences[J]. Chinese Journal of Power Sources, 2025, 49(04): 764-771.
- [12] 杜伟,王圣,李健,等. 基于 CNN-LSTM-AM 模型的储能锂离子电池荷电状态预测[J]. 电工技术学报, 2025, 40(9): 2982-2995.
DU W, WANG S, LI J, et al. State of charge prediction of energy storage lithium-ion batteries based on CNN-LSTM-AM model[J]. Transactions of China Electrotechnical Society, 2025, 40(9): 2982-2995.
- [13] 程思涵,刘思懿,郭子旭,等. 基于 CNN-GRU-注意力的锂离子电池

- SOC 估计[J]. 电池, 2026, 56(01): 131-135. DOI: 10.19535/j. 1001-1579.2026.01.019.
- CHENG S H, LIU S Y, GUO Z X, et al. SOC estimation of lithium-ion batteries based on CNN-GRU-attention[J]. Battery Bimonthly, 2026, 56(01): 131-135. DOI: 10.19535/j.1001-1579.2026.01.019.
- [14] 马昊远,吴焱,王通,等. 基于力-电-温度信号和 CNN-BiLSTM 模型的磷酸铁锂电池 SOC 估计[J]. 储能科学与技术, 2025, 14(07): 2865-2874. DOI: 10.19799/j.cnki.2095-4239.2025.0062.
- MA H Y, WU Y, WANG T, et al. SOC estimation of lithium iron phosphate batteries based on force-electric-thermal signals and CNN-BiLSTM model[J]. Energy Storage Science and Technology, 2025, 14(07): 2865-2874. DOI: 10.19799/j. cnki. 2095-4239.2025.0062.
- [15] FENG X, CHEN J, ZHANG Z, et al. State-of-charge estimation of lithium-ion battery based on clockwork recurrent neural network [J]. Energy, 2021, 236: 121360. DOI: 10.1016/j.energy.2021.121360.
- [16] 谭必蓉,杜建华,叶祥虎,等. 基于模型的锂离子电池 SOC 估计方法综述[J]. 储能科学与技术, 2023, 12(06): 1995-2010. DOI: 10.19799/j.cnki.2095-4239.2023.0016.
- TAN B R, DU J H, YE X H, et al. Review of model-based SOC estimation methods for lithium-ion batteries[J]. Energy Storage Science and Technology, 2023, 12(06): 1995-2010. DOI: 10.19799/j.cnki.2095-4239.2023.0016.
- [17] 吕高,樊郭宇,张嘉蕾,等. 温度自适应 SMO 算法估计锂离子电池的 SOC[J]. 电池, 2024, 54(03): 334-339. DOI: 10.19535/j. 1001-1579.2024.03.009.
- LÜ G, FAN G Y, ZHANG J L, et al. SOC estimation of lithium-ion batteries using temperature-adaptive SMO algorithm[J]. Battery Bimonthly, 2024, 54(03): 334-339. DOI: 10.19535/j. 1001-1579.2024.03.009.
- [18] LI H, YU H, ZHU R, et al. Distributed finite-time $S^{\circ}C$ estimation for lithium-ion battery packs[J]. IEEE Transactions on Industrial Electronics, 2026. DOI: 10.1109/TIE.2026.3661048.
- [19] ZHANG S, WANG X, CHEN Z, et al. Antidisturbance state-of-charge estimation for lithium-ion batteries using nonlinear extended state observers[J]. IEEE Transactions on Transportation Electrification, 2025, 11: 2918-2928. DOI: 10.1109/TTE.2024.3430540.
- [20] WU X, LI X, DU J. State of charge estimation of lithium-ion batteries over wide temperature range using unscented Kalman filter[J]. IEEE Access, 2018, 6: 41993-42003. DOI: 10.1109/ACCESS.2018.2860050.
- [21] WANG Y, CHENG Y, XIONG Y, et al. Estimation of battery open-circuit voltage and state of charge based on dynamic matrix control-extended Kalman filter algorithm[J]. Journal of Energy Storage, 2022, 52: 104860. DOI: 10.1016/j.est.2022.104860.
- [22] DU J, WANG J, TAN B, et al. Estimation of battery state of charge based on changing window adaptive extended Kalman filtering[J]. Journal of Energy Storage, 2024, 103: 114325. DOI: 10.1016/j.est.2024.114325.
- [23] ZHANG K, XIONG R, LI Q, et al. A novel pseudo-open-circuit voltage modeling method for accurate state-of-charge estimation of LiFePO₄ batteries[J]. Applied Energy, 2023, 347: 121406. DOI: 10.1016/j.apenergy.2023.121406.
- [24] JIANG Y, XU J, LIU M, et al. An electromechanical coupling model-based state of charge estimation method for lithium-ion pouch battery modules[J]. Energy, 2022, 259: 125019. DOI: 10.1016/j.energy.2022.125019.
- [25] XIONG R, LI Z, WANG P, et al. Advanced electrical-mechanical hybrid approach for enhanced state of charge estimation of lithium-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2026, 73: 5687-5697. DOI: 10.1109/TIE.2025.3634458.
- [26] FU J, WU C, WANG J, et al. Lithium-ion battery SOH prediction based on VMD-PE and improved DBO optimized temporal convolutional network model[J]. Journal of Energy Storage, 2024, 87: 111392. DOI: 10.1016/j.est.2024.111392.
- [27] He X, Sun K, He Y, et al. Mechanistic insights into the dynamic evolution processes of LiFePO₄/C batteries[J]. Chemical Engineering Journal, 2025, 515: 163447.
- [28] ZHAO H, MENG J, PENG Q. Early perception of lithium-ion battery degradation trajectory with graphical features and deep learning[J]. Applied Energy, 2025, 381: 125214. DOI: 10.1016/j.apenergy.2024.125214.
- [29] LIU Q, MA J, ZHAO X, et al. Voltage fault diagnosis and misdiagnosis analysis of battery systems using the modified Shannon entropy in real-world electric vehicles[J]. Journal of Energy Storage, 2023, 73: 109287. DOI: 10.1016/j.est.2023.109287.

附录 A

表 A.1 PI-EWAEKF 方法用于 LFP 电池 SOC 估计的计算流程

Table A.1 Calculation procedure of the proposed PI-EWAEKF for SOC estimation of LFP batteries

计算阶段	基于 RLS 的二阶 RC 模型参数辨识	熵权协方差自适应更新	PI-EWAEKF 联合 SOC 估计
初始化	OCV-SOC 曲线: $U_{oc}(SOC) = \sum_{i=1}^9 a_i SOC^i$	$R^{(0)} = diag([10^{-5},10])$	表面力-SOC 曲线: $F_p(SOC) = \sum_{i=0}^9 f_i SOC^i$ $\begin{cases} X^{(0)}=[U_1^{(0)},U_2^{(0)},SOC^{(0)},F_{bias}^{(0)}]^T \\ Z^{(0)}=[U_i^{(0)},F_q^{(0)}]^T \\ P^{(0)}=diag([10^{-3},10^{-3},10^{-3},10^{-6}]) \\ Q^{(0)}=diag([10^{-6},10^{-6},10^{-7},10^{-5}]) \end{cases}$ 额定容量 $C_n = 32Ah$
	RLS: $\begin{cases} I^{(-1)}=I^{(0)}=0 \\ \theta^{(0)}=[0.01,0.01,0.01,0.01,0.01]^T \\ P_M^{(0)}=diag([10^2,10^2,10^2,10^2,10^2]) \end{cases}$	香农熵: $H_U^{(k)}=-\sum_{i=1}^n p_{U,i}^{(k)} \ln(p_{U,i}^{(k)})$ $H_F^{(k)}=-\sum_{i=1}^n p_{F,i}^{(k)} \ln(p_{F,i}^{(k)})$ 归一化香农熵: $\bar{H}_U^{(k)}=\frac{H_U^{(k)}}{\ln n}, \bar{H}_F^{(k)}=\frac{H_F^{(k)}}{\ln n}$ 可观性因子: $S_U^{(k)}=\frac{ \bar{g}_U^{(k)} }{ \bar{g}_U^{(k)} + \bar{g}_F^{(k)} +\varepsilon}$ $S_F^{(k)}=\frac{ \bar{g}_F^{(k)} }{ \bar{g}_U^{(k)} + \bar{g}_F^{(k)} +\varepsilon}$ 信号置信度: $C_U^{(k)}=\exp(-\lambda \bar{H}_U^{(k)}) S_U^{(k)}$ $C_F^{(k)}=\exp(-\lambda \bar{H}_F^{(k)}) S_F^{(k)}$ 测量噪声协方差更新: $R_U^{(k)}=R_{U,\min}+(R_{U,\max}-R_{U,\min})(1-C_U^{(k)})$ $R_F^{(k)}=R_{F,\min}+(R_{F,\max}-R_{F,\min})(1-C_F^{(k)})$ $R^{(k)}=diag(R_U^{(k)},R_F^{(k)})$	先验更新: $\begin{cases} A_{k-1}=diag\left(e^{\frac{T}{R_1C_1}},e^{\frac{T}{R_2C_2}},1,1\right) \\ B_{k-1}=\left[R_1\left(1-e^{-\frac{T}{R_1C_1}}\right),R_2\left(1-e^{-\frac{T}{R_2C_2}}\right),-\frac{\eta T}{C_n},0\right]^T \\ x_{k k-1}=A_{k-1}x_{k-1}+B_{k-1}I_{k-1} \\ P_{k k-1}=A_{k-1}P_{k-1}A_{k-1}^T+Q \end{cases}$
在线参数辨识	输入变量: $\begin{cases} y^{(k)}=U_{oc}^{(k)}-U^{(k)} \\ \phi^{(k)}=[y^{(k-1)},y^{(k-2)},I^{(k)},I^{(k-1)},I^{(k-2)}]^T \end{cases}$ 参数向量: $\theta^{(k)}=[\beta_1^{(k)},\beta_2^{(k)},\beta_3^{(k)},\beta_4^{(k)},\beta_5^{(k)}]^T$ 参数更新: $\begin{cases} \theta^{(k)}=\theta^{(k-1)}+K^{(k)}[y^{(k)}-\phi^{(k)T}\theta^{(k-1)}] \\ K^{(k)}=\frac{P_M^{(k-1)}\phi^{(k)}}{1+\phi^{(k)T}P_M^{(k-1)}\phi^{(k)}} \\ P_M^{(k)}=[I-K^{(k)}\phi^{(k)T}]P_M^{(k-1)} \end{cases}$		
电-表面力联合估计	参数求解: $\begin{cases} \beta_0=\frac{T^2}{\beta_1+\beta_2+1},R_0=\frac{\beta_5}{\beta_2} \\ \tau_1=\frac{\frac{\beta_0(\beta_1+2\beta_2)}{T}+\sqrt{[\frac{\beta_0(\beta_1+2\beta_2)}{T}]^2-4\beta_0\beta_2}}{2} \\ \tau_2=\frac{\frac{\beta_0(\beta_1+2\beta_2)}{T}-\sqrt{[\frac{\beta_0(\beta_1+2\beta_2)}{T}]^2-4\beta_0\beta_2}}{2} \\ R_1=\frac{\tau_1\frac{\beta_0(\beta_3+\beta_4+\beta_5)}{T^2}+\tau_2R_0-\frac{\beta_0(\beta_4+2\beta_5)}{T}}{\tau_1-\tau_2} \\ R_2=\frac{\beta_0(\beta_3+\beta_4+\beta_5)}{T^2}-R_1-R_0 \\ C_1=\frac{\tau_1}{R_1},C_2=\frac{\tau_2}{R_2} \end{cases}$		后验更新: $\hat{z}_k=\begin{bmatrix} U_{oc}(SOC_{k k-1})-U_{1,k k-1}-U_{2,k k-1}-I_kR_0 \\ F_p(SOC_{k k-1})+F_{ew,k k-1} \end{bmatrix}$ $H_k=\begin{bmatrix} -1 & -1 & \frac{\partial U_{oc}}{\partial SOC} & 0 \\ 0 & 0 & \frac{\partial F_p}{\partial SOC} & 1 \end{bmatrix}$ $K_k=P_{k k-1}H_k^T(H_kP_{k k-1}H_k^T+R^{(k)})^{-1}$ $x_k=x_{k k-1}+K_k(z_k-\hat{z}_k)$ $P_k=(I-K_kH_k)P_{k k-1}$

表 A.2 PI-EWAEKF 方法中的超参数设置情况

Table A.2 Hyperparameter settings of the PI-EWAEKF method

参数	含义	本文取值	选取依据
L	香农熵计算的滑动窗口长度	100	根据 1 Hz 采样频率和动态工况响应速度确定，兼顾统计稳定性与实时性。
n	熵计算的区间划分数	10	与窗口长度匹配，用于保证概率统计稳定性和熵值分辨率。
λ	熵权正则化系数	1.3	通过多组实验调试获得，用于调节归一化熵对信号置信度的影响强度。
ε	防止分母为零的小量	10^{-6}	用于避免梯度接近零时出现数值奇异。
Q	状态转移过程噪声协方差矩阵	$\text{diag}(10^{-6}, 10^{-6}, 10^{-7}, 10^{-5})$	根据模型误差及实验噪声水平设定，用于表征状态预测不确定性。
R_0	初始测量噪声协方差矩阵	$\text{diag}(10^{-5}, 10)$	根据电压传感器与表面力传感器精度设置，为熵权自适应更新提供初始基准。
$R_{F,\min}, R_{F,\max}$	表面力通道测量噪声方差上下限	$10, 4 \times 10^2$	用于约束测量噪声方差的在线更新范围，避免观测权重过大或过小。
$R_{U,\min}, R_{U,\max}$	电压通道测量噪声方差上下限	$10^{-5}, 10^{-3}$	用于约束电压通道测量噪声的自适应更新范围。
P_0	初始状态协方差矩阵	$\text{diag}(10^{-2}, 10^{-3}, 10^{-3}, 10^{-5})$	反映滤波器初始不确定性，较大的 SOC 方差有利于提高初始收敛速度。
Δt	采样周期	1 s	与实验采样频率一致。




图 A.1 不同温度和老化状态下的 OCV-SOC 曲线
Fig. A.1 OCV-SOC curves under different temperatures and aging states




图 A.2 二阶 RC 模型参数辨识结果：(a) 电阻参数；(b) 极化电容参数

Fig. A.2 Identification results of second-order RC model parameters: (a) resistance parameters; (b) capacitance parameters