

DOI: 10.13382/j.jemi.B2407827

# 基于 EKF-HInformer 模型估计汽车动力电池的 SOC&SOH<sup>\*</sup>

彭自然<sup>1,2</sup> 杨肖阳<sup>1,2</sup> 肖伸平<sup>1,2</sup>

(1. 湖南工业大学电气与信息工程学院 株洲 412007; 2. 电传动控制与智能装备湖南省重点实验室 株洲 412007)

**摘要:**针对传统模型荷电状态(SOC)和健康状态(SOH)估计精度低、鲁棒性差的问题,提出一种基于扩展卡尔曼滤波(EKF)和深度学习模型 Informer 改进优化的估计模型 EKF-HInformer,实现电动汽车动力电池 SOC 与 SOH 的实时精准估计。首先,运用 EKF 算法归一化整理电池实时数据,并通过调整自适应增益因子减少噪声波动,提高 EKF 数据滤波处理的性能。然后,运用 Informer 网络模型对归一化后的电池数据进行智能估计。为减少 Informer 模型离群点或异常值所导致的注意力权重偏差问题,采用 Hampel 算法对 Informer 进行优化,提高多头概率稀疏自注意力机制特征学习的能力。最后,把滤波整理后的数据输入到 HInformer 网络中估算实时的 SOC 和 SOH。采用牛津大学与马里兰大学的电池数据集进行实验验证,结果显示 SOC 与 SOH 估计精度均超 99.5%,均方根误差(RMSE)小于 1%,最大绝对误差(MAXE)小于 0.5%。相比传统 Informer、Transformer 和长短期记忆(LSTM)模型,该模型估计 SOC 和 SOH 的速度更快、准确度更高,展现出优越的鲁棒性和泛化能力。

**关键词:** 动力电池;荷电状态;健康状态;自适应增益因子;扩展卡尔曼滤波;Hampel 优化算法;Informer

**中图分类号:** TN919.5; TP183 **文献标识码:** A **国家标准学科分类代码:** 470.40

## SOC and SOH of the battery are estimated based on the EKF-HInformer model

Peng Ziran<sup>1,2</sup> Yang Xiaoyang<sup>1,2</sup> Xiao Shenping<sup>1,2</sup>

(1. College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou 412007, China;

2. Hunan Key Laboratory of Electric Drive Control and Intelligent Equipment, Zhuzhou 412007, China)

**Abstract:** To address the issues of low accuracy and poor robustness in traditional state of charge (SOC) and state of health (SOH) estimation models, an improved model, EKF-HInformer, is proposed based on the extended Kalman filter (EKF) and the deep learning model Informer. This model enables real-time and accurate estimation of the SOC and SOH of electric vehicle batteries. First, the EKF algorithm is used to normalize the real-time battery data, and the adaptive gain factor is adjusted to reduce noise fluctuations, enhancing the performance of EKF data filtering. Then, the Informer network model is used to intelligently estimate the normalized battery data. To reduce the bias in attention weights caused by outliers or abnormal values, the Hampel algorithm is applied to optimize the Informer model, improving the feature learning ability of the multi-head probabilistic sparse self-attention mechanism. Finally, the filtered data is fed into the HInformer network to estimate real-time SOC and SOH. Experiments are conducted using battery datasets from the University of Oxford and the University of Maryland. The results show that the estimation accuracy for SOC and SOH exceeds 99.5%, with RMSE less than 1% and MAXE less than 0.5%. Compared to traditional Informer, Transformer, and LSTM models, this model is faster and more accurate in estimating SOC and SOH, demonstrating superior robustness and generalization ability.

**Keywords:** power battery; state of health; state of charge; adaptive gain factor; extended Kalman filter; Hampel optimisation algorithm; Informer

收稿日期: 2024-09-15 Received Date: 2024-09-15

\* 基金项目: 国家重点研发计划基金(2019YFE0122600)、湖南省教育厅重点科研项目(22A0423)、湖南省自然科学基金(2023JJ60267, 2022JJ50073)项目资助

## 0 引言

动力电池组作为电动汽车的核心能源装置之一,通常由数百个电池单元以串联或并联形式组成,从而满足车辆行驶所需的动力<sup>[1-2]</sup>。目前,动力电池主要以铅酸电池、镍氢电池和锂离子电池为主<sup>[3]</sup>。但电池在使用过程中容易受容量衰减、内阻增加以及温度过高等因素的影响,导致电池性能下降、寿命缩短,进而影响动力电池的正常工作<sup>[4-6]</sup>。因此,为确保电动汽车能够更加安全稳定的运行,对动力电池组的荷电状态(state of charge, SOC)和健康状态(state of health, SOH)进行精确估计和监测变的至关重要<sup>[7]</sup>。

目前动力电池 SOC 和 SOH 估算的方法主要分为两类,基于模型的方法<sup>[8]</sup>和基于数据驱动的方法<sup>[9]</sup>。基于模型的方法是根据动力电池组的退化和失效机理,建立相应的数学和物理模型表征电池性能退化的过程,实现对 SOH 和 SOC 的估计<sup>[10]</sup>。但这种方法十分依赖模型的准确性,且构建模型和求解过程较为困难。基于数据驱动的方法则不需要复杂的等效模型,可以直接从电池测试数据(如电压、电流、温度、阻抗等)中挖掘隐藏的电池健康信息及其演化规律,实现动力电池 SOH 和 SOC 的估计。该方法不仅简化了预测流程,还提高了估计精度和效率,故而得到了广泛的应用。

基于数据驱动的方法主要通过神经网络(neural network, NN)算法模型<sup>[11]</sup>学习数据的复杂关系,从而实现对 SOC 和 SOH 的精准估计。文献[12]提出了一种基于注意力机制优化长短期记忆网络(long short-term memory, LSTM)估计 SOC 的方法,该方法通过经验模态分解对电池数据进行预处理,并将处理后的数据输入到优化后的 LSTM 模型中,从而有效提升了 SOC 的估计精度。但上述方法仅对 SOC 进行了单一估计,忽略了电池老化对 SOC 产生的影响,使得估计结果准确性降低<sup>[13]</sup>。文献[14]提出一种具有动态映射能力的改进动态递归神经网络(DRNN)估计 SOC 和 SOH 的方法,通过利用电池的温度、老化程度等特征,并用 SOH 估计值补偿 SOC 估计误差,有效提高了 SOC 和 SOH 的估计精度。但 DRNN 和 LSTM 均存在梯度消失和梯度爆炸等问题,这将导致模型性能下降并增加训练难度。文献[15]引入了一种基于 U-Net 结构的卷积神经网络(CNN)来估算 SOC,该结构能够处理变长度的输入和输出数据,不存在梯度问题,使得 SOC 的估计精度得到了进一步的提升。但该模型对长时间依赖的捕捉能力有限,且难以处理复杂的时序特征。近年来,Transformer 模型凭借其优越的

注意力机制,能够高效捕获历史数据中的关键特征,从而在时间序列预测任务中得到了广泛应用。文献[16]利用 Transformer 的多头自注意力机制提出了一种专门用于预测电池 SOC 的模型,该模型能够识别和强调关键数据点,并允许关注不同的序列长度和依赖关系。文献[17]则将自监督学习(self-supervised learning, SSL)与 Transformer 相结合,不仅显著减少了模型的训练时间,还提升了 SOC 的估计精度。然而,Transformer 的自我注意力机制在处理长序列时,计算和内存需求显著增加,导致模型性能下降<sup>[18]</sup>。文献[19]提出了一种基于 Informer 模型的电动汽车 SOH 估计方法,该方法通过 Informer 模型捕捉并理解健康指标与 SOH 之间的全面关联性和相互影响,有效提高了 SOH 估计的准确性。但在时间序列预测过程中,Informer 模型的多头概率稀疏自注意力机制(PPSA)会出现异常偏差,这将会导致其错误收集潜在特征,使得模型性能降低<sup>[20]</sup>。

当电动汽车在充放电时,电池管理系统(battery management system, BMS)通过传感器收集大量的电压、电流和温度数据。但由于电池内部复杂变化、外部环境波动以及电磁干扰等因素,BMS 可能采集到异常或含有噪声的数据<sup>[21]</sup>,从而影响 SOC 和 SOH 的估计精度。文献[22-23]均使用降噪自编码器(denoising autoencoder, DAE)对带有噪声的输入特征进行处理,使得估计精度有了明显的提升,因此对数据进行相关性分析和滤波处理是非常重要的。但 DAE 处理 BMS 数据时依赖大量高质量训练数据,实时性较差,影响估计的准确性和实时性。

针对现有 SOC 和 SOH 估计方法在数据处理精度、模型泛化能力及计算效率等方面的局限性,提出了一种基于 Informer 架构改进的联合估计模型,该模型通过扩展卡尔曼滤波(extended Kalman filter, EKF)与 HInformer 网络,实现了对电动汽车动力电池 SOC 和 SOH 的高精度联合估计。

1) 针对 DAE 对大量数据的依赖性,使用 EKF 对采集到的数据进行滤波校正。创新性的引入了自适应增益因子减少噪声特性波动对数据处理时的影响,以提升 EKF 的鲁棒性和跟踪性能。

2) 针对 Transformer 在长时间序列预测任务中存在的计算复杂度高等缺点,采用了 Informer 模型,以提升长时间序列预测任务的性能。创新性的利用 Hampel 算法对 Informer 模型进行优化,有效降低了 PPSA 模块特征采集时的异常偏差。

3) 考虑到 SOC 与 SOH 之间的相关性,进行 SOH 估计时将 SOC 作为输入特征,从而降低电池充放电效率变化等因素导致的估计误差,提升模型的估计精度。

## 1 相关工作

### 1.1 数据的采集分析

电动汽车的动力电池组通常由十几个电池模块以并联或串联的形式构成,每个电池模块又由多个单体电池组成,电动汽车电池组结构如图1所示,该电池组是由16个电池模块7104个电池单元组成的。

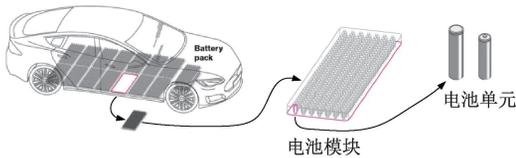


图1 电动汽车电池组结构

Fig.1 Electric vehicle battery pack structure

动力电池组由BMS进行管理与控制,BMS主要由数据采集模块、中央控制单元(通常包括电池感测单元(battery sensing unit, BSU)和电池管理单元(battery management unit, BMU))以及通信模块等组成,共同确保动力电池的安全与效率。数据采集模块的核心任务是实时采集和处理电池的电压、电流及温度等关键数据,大致过程如图2所示。

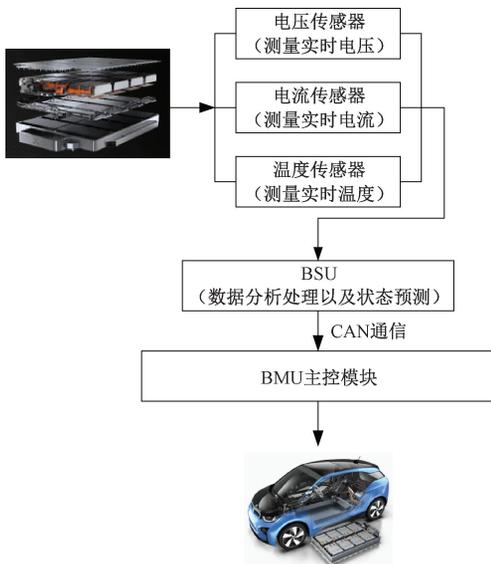


图2 电动汽车电池数据采集流程

Fig.2 Electric vehicle battery data acquisition process

首先,数据采集模块利用CAN通信,接收来自电压传感器测量的电池组内各单体或模块的电压数据,同时收集霍尔传感器或分流器所测量的电池组充放电电流数据以及温度传感器所测量的电池工作温度数据。然后,通过通信总线(如CAN总线或SPI接口)将采集

的数据传输到BSU单元。BSU负责实时监测每个电池单元的电压、电流和温度,对数据进行分析和处理,生成相关的状态信息。最后,通过CAN通信将这些数据传输给BMU,BMU接收数据后,将其整合形成综合状态信息,并进行深度分析以评估动力电池组的SOC和SOH。

### 1.2 EKF的基本原理

电动汽车在充放电过程中,BMS通过传感器采集电压、电流和温度等数据,但其中的异常和噪声数据会影响SOC和SOH的估计精度。以采集的电压数据为例,如图3所示。从图3可以观察到,电压信号中的噪声和异常数据导致电压曲线出现波动,降低了数据的平滑性,这将会引起SOC和SOH估计的抖动与误差累积。为有效减小这些影响,针对动力电池组复杂的动态特性和非线性行为,提出采用EKF对数据进行滤波与校正,以提升输入数据的准确性。

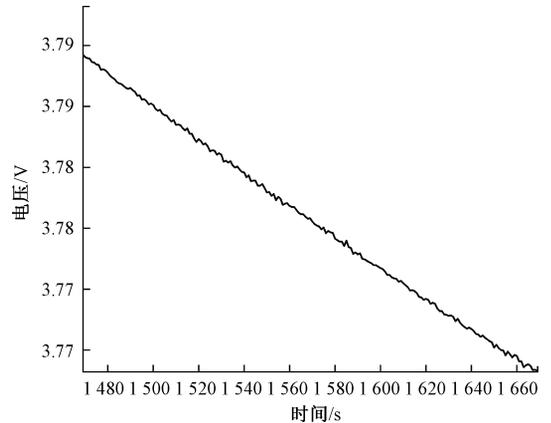


图3 电压数据变化曲线

Fig.3 Voltage data change curve

EKF是基于卡尔曼滤波(Kalman filter, KF)的一种改进,主要是通过泰勒展开将非线性状态转移和观测模型线性化,使用雅可比矩阵代替线性模型中的常数矩阵,进而解决KF在处理非线性问题时的局限性。EKF处理数据过程可以分为预测阶段和更新阶段两个阶段。

定义EKF的状态方程和观测方程如式(1)所示。

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_{k-1} \\ \mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k \end{cases} \quad (1)$$

式中: $\mathbf{x}_k$ 是k时刻预测出的状态向量; $\mathbf{z}_k$ 是k时刻的观测值; $h(\cdot)$ 为观测模型函数; $f(\cdot)$ 是非线性状态转移函数; $\mathbf{u}_{k-1}$ 是k-1时刻的控制输入; $\mathbf{w}_{k-1}$ 是k-1时刻的过程噪声; $\mathbf{v}_k$ 是k时刻的观测噪声。

1) 预测阶段

状态预测方程:

$$\mathbf{x}_k = f(\mathbf{x}'_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_{k-1} \quad (2)$$

式中:  $\mathbf{x}'_{k-1}$  是  $k-1$  时刻的状态向量。

预测协方差:

$$\mathbf{P}_k = \mathbf{F}_{k-1} \mathbf{P}'_{k-1} \mathbf{F}_{k-1}^T + \mathbf{Q}_{k-1} \quad (3)$$

式中:  $\mathbf{P}'_{k-1}$  是  $k-1$  时刻的协方差矩阵;  $\mathbf{Q}_{k-1}$  是过程噪声协

方差矩阵;  $\mathbf{F}_{k-1} = \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}_{k-1}, \mathbf{u}=\mathbf{u}_{k-1}}$  是状态转移函数的雅可比矩阵。

卡尔曼增益:

$$\mathbf{K}_k = \mathbf{P}_k \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (4)$$

式中:  $\mathbf{R}_k$  是测量噪声协方差;  $\mathbf{H}_k = \left. \frac{\partial h}{\partial \mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}_k}$  是观测函数的雅可比矩阵;  $\mathbf{S}_k$  为残差协方差矩阵计算如式(5)所示。

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R}_k \quad (5)$$

2) 状态更新

状态更新和协方差更新如式(6)所示。

$$\begin{cases} \mathbf{x}'_k = \mathbf{x}_k + \mathbf{K}_k (\mathbf{z}_k - h(\mathbf{x}_k)) \\ \mathbf{P}'_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k \end{cases} \quad (6)$$

综上所述, EKF 通过在预测阶段利用先前采集到的数据进行状态估计, 并在更新阶段结合当前观测值对估计结果进行修正, 从而实现在非线性和噪声环境中对数据的整理和校正。

### 1.3 Informer 模型

Informer 作为 Transformer 的一种变体, 主要由编码器和解码器构成, 结构如图 4 所示。其编码器主要由 PPSA 和自注意力蒸馏层构成。该模型有效解决了 Transformer 在处理长序列问题时的缺点, 如自注意的二次计算、长输入堆栈层存储的瓶颈以及预测长期输出速度的降低。相较于 LSTM、门控循环单元(gated recurrent unit, GRU) 以及标准 Transformer 等其他预测模型, Informer 模型能够有效处理大量的历史数据, 捕捉长时间的依赖关系, 同时确保计算效率和内存利用率。这对于电动汽车电池管理系统中需要实时、精准的 SOC 和 SOH 估计来说尤为关键。

在 Informer 模型中, PPSA 通过筛选并保留对结果影响较大的注意力分数, 实现注意力机制的稀疏化, 从而减轻计算负荷。

首先, 通过式(7)定义第  $i$  个向量查询的稀疏度量。

$$\bar{M}(\mathbf{q}_i, \mathbf{K}) = \max_j \left( \frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{d}} \right) - \frac{1}{L_K} \sum_{j=1}^{L_K} \frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{d}} \quad (7)$$

$$A(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax} \left( \frac{\bar{\mathbf{Q}} \mathbf{K}^T}{\sqrt{d}} \right) \mathbf{V} \quad (8)$$

然后, 将计算得分最高的  $m$  个主要查询向量组成  $\bar{\mathbf{Q}}$ 。最后, 通过式(8) 计算  $m$  个主要查询向量  $\mathbf{q}_i$  的注意力得分。

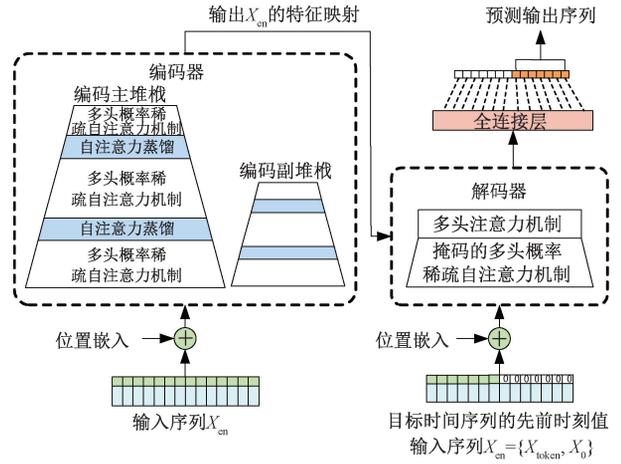


图 4 Informer 网络结构

Fig. 4 Informer network structure

## 2 EKF 处理数据及其改进

### 2.1 EKF 的改进

传统的 EKF 通过固定公式计算卡尔曼增益, 依赖于预测协方差、观测矩阵和观测噪声协方差。然而, 在实际的数据采集过程中, 过程噪声和观测噪声会随时间变化。为此, 本文创新性的引入了自适应增益因子  $\alpha_k$ , 以提升 EKF 的数据处理性能。当噪声水平变化时, 残差(观测值与预测值之间的差异)能够反映这种变化。 $\alpha_k$  利用这些残差信息, 动态调整滤波器对观测值和预测值的权重, 从而保持滤波器的稳定性和准确性, 计算如式(9)所示。具体而言,  $\alpha_k$  根据当前的观测残差与残差协方差的关系, 动态调整卡尔曼增益。当观测误差较大时,  $\alpha_k$  增大, 使得滤波器更依赖于预测值; 反之, 当观测误差较小时,  $\alpha_k$  减小, 增强滤波器对观测值的依赖。

$$\alpha_k = 1 + \frac{\mathbf{e}_k^T \mathbf{S}_k^{-1} \mathbf{e}_k}{m} \quad (9)$$

式中:  $\mathbf{e}_k = \mathbf{z}_k - h(\mathbf{x}_k)$  为残差;  $\mathbf{e}_k^T \mathbf{S}_k^{-1} \mathbf{e}_k$  为残差的加权二次型, 表示当前时刻残差的大小与预测协方差的关系;  $m$  是观测向量的维数, 该模型设定  $m=3$ 。

根据自适应增益因子调整后的卡尔曼增益如式(10)所示。

$$\mathbf{K}_k = \alpha_k \mathbf{P}_k \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (10)$$

引入自适应增益因子后的状态更新和协方差更新方程如式(11)所示。

$$\begin{cases} \mathbf{x}'_k = \mathbf{x}_k + \mathbf{K}_k \mathbf{e}_k \\ \mathbf{P}'_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k \end{cases} \quad (11)$$

综上所述, 自适应增益因子的引入, 使得 EKF 在面对不确定性和动态变化的噪声环境时, 能够更灵活的调

整滤波策略。这种灵活性可以有效减少噪声变化带来的处理偏差,提高 EKF 数据处理的鲁棒性和跟踪性能。以牛津大学电池 Cell1 的采集电压数据为例,经过增加自适应增益因子后的 EKF 处理,其数据曲线呈现出更加平滑和稳定的特征,处理结果如图 5 所示。

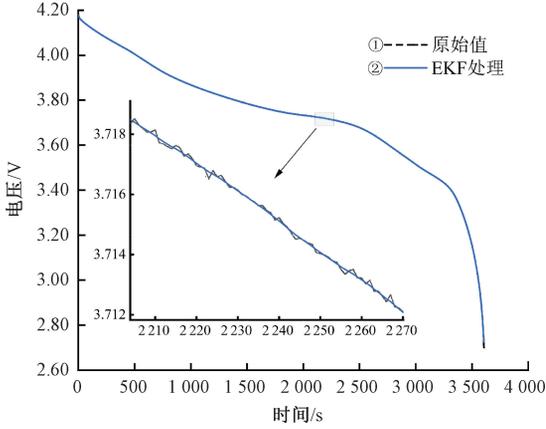


图 5 电压数据处理后的效果

Fig. 5 Effect of voltage data processing

## 2.2 数据整理和校正

EKF 通过迭代的方式不断更新对数据的估计,分析电池内部温度对电压和电流的影响,滤波整理并校正电压、电流。这种方法可以有效削弱因电池内部电化学反应以及温度变化等原因造成的数据波动,减少异常、噪声数据对 SOC 和 SOH 估计的影响。从电动汽车动力电池组中采集到的电压、电流和温度数据经过归一化处理,输入到经过自适应增益因子改进的 EKF 中进行处理,具体流程如图 6 所示。

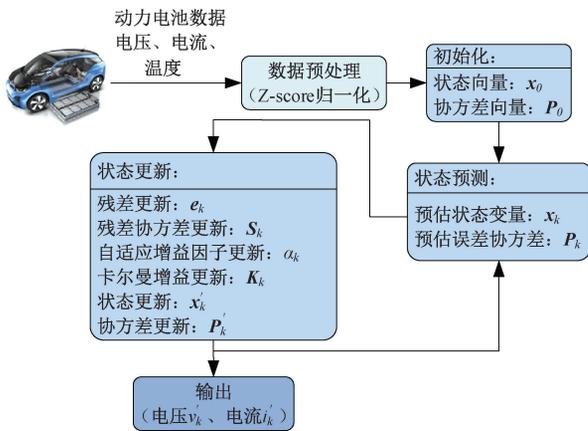


图 6 EKF 数据处理流程

Fig. 6 Flowchart of data processing of the improved EKF algorithm

列长度)、电流  $I=[i_0, i_1, \dots, i_{L_i}]$  ( $L_i$  为  $i$  的序列长度) 和温度  $T=[t_0, t_1, \dots, t_{L_t}]$  ( $L_t$  为  $t$  的序列长度) 进行归一化处理。然后,将归一化后的数据输入到经过自适应增益因子改进的 EKF 中进行处理,处理过程如下。

初始化,设置初始状态向量和协方差矩阵如式(12)和(13)所示。

$$\mathbf{x}_0 = \begin{bmatrix} v_0 \\ i_0 \\ t_0 \end{bmatrix} \quad (12)$$

$$\mathbf{P}_0 = \frac{1}{L_x - 1} \sum_{k=1}^{L_x} \left( \mathbf{x}_k - \frac{1}{L_x} \sum_{k=1}^{L_x} \mathbf{x}_k \right) \left( \mathbf{x}_k - \frac{1}{L_x} \sum_{k=1}^{L_x} \mathbf{x}_k \right)^T \quad (13)$$

式中:  $k \in [0, L_x]$ 。

### 1) 状态预测

利用电池当前状态预测下一个时刻的电压和电流,同时考虑温度的影响。状态预测方程如式(14)所示。

$$\mathbf{x}_k = f(\mathbf{x}'_{k-1}) + \mathbf{w}_{k-1} \quad (14)$$

对于电动汽车动力电池组,状态转移函数  $f(\cdot)$  如式(15)所示。

$$f(\mathbf{x}_{k-1}) = \begin{bmatrix} f_v(v_{k-1}, i_{k-1}, t_{k-1}) \\ f_i(v_{k-1}, i_{k-1}, t_{k-1}) \\ f_t(v_{k-1}, i_{k-1}, t_{k-1}) \end{bmatrix} \quad (15)$$

式中:  $f_v$  和  $f_i$  是电压和电流随温度变化的函数;  $f_t$  是温度随电压和电流变化的函数。

利用式(3)计算得出预测协方差矩阵  $\mathbf{P}_k$ 。

### 2) 状态更新

残差更新如下:

$$\mathbf{e}_k = \mathbf{z}_k - h(\mathbf{x}_k) \quad (16)$$

通过式(5)、(9)和(10)对  $\mathbf{S}_k$ 、 $\alpha_k$  与  $\mathbf{K}_k$  进行更新。同时根据实际测得的电压和电流,利用式(11)更新得到状态向量  $\mathbf{x}'_k$  和协方差  $\mathbf{P}'_k$ 。最后,输出滤波处理后的精确电压和电流值。

输出的状态向量为:

$$\mathbf{x}'_k = \begin{bmatrix} v'_k \\ i'_k \end{bmatrix} \quad (17)$$

## 3 Informer 模型优化

Informer 模型通过 KL 发散的方法,将 PPSA 的注意力集中在概率分布中不均匀的区域,选择离群点作为主要贡献者。但这一选择过程会对注意力分布产生持久的影响,将会在特征学习中引入偏见,导致收集到错误的潜在特征。为了减轻偏向注意对特征学习过程的影响,本文采用了具有孤立点过滤功能的 Hampel 算法去优化 PPSA,进一步提高 PPSA 特征学习的能力,以提升

首先,将采集的电压  $V=[v_0, v_1, \dots, v_{L_v}]$  ( $L_v$  为  $v$  的序

Informer 模型的估计性能。改进优化后的 Informer 模型结构如图 7 所示。

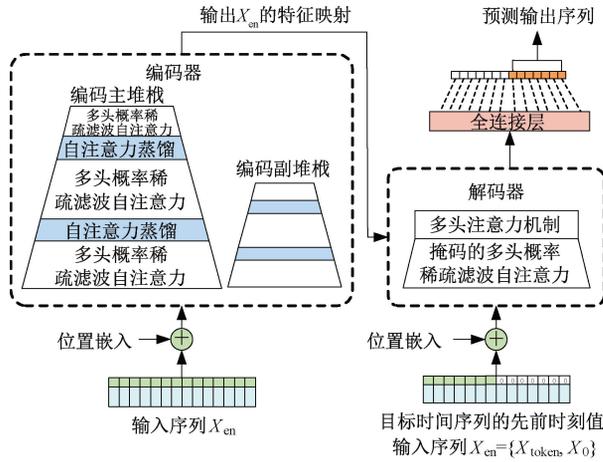


图 7 HInformer 结构

Fig. 7 Structure diagram of the HInformer model

### 3.1 优化多头概率稀疏自注意力机制

Hampel 算法是一种处理时序数据异常值(噪声或离群点)的有效方法。该算法基于统计学中的 Hampel 识别规则,采用数据的中心值(即中位数)作为基准,通过对数据进行优化,增强模型在处理异常数据时的稳定性。通过定义偏差阈值,识别并削弱因离群点或异常值所导致的注意力权重偏差问题。同时,对注意力权重分布中可能存在的偏斜和不均匀性进行纠正,从而提升模型的整体性能及估计的准确性。

Hampel 优化算法作用如图 8 所示。输入的时间序列数据  $X = [V, I] \in R^{T \times 2d}$ , 即输入到模型中的电压数据为  $V \in R^{T \times d}$ , 电流数据为  $I \in R^{T \times d}$ , 其中  $T$  是时间步数,  $d$  是特征维度。首先,将输入的时间序列数据通过多头自注意力机制映射为查询矩阵  $Q$ 、键矩阵  $K$  和值矩阵  $V$ , 并依据式(7)和式(8)筛选出关键的注意力得分。然后,通过式(18)计算出多头自注意力机制中每个头的权重矩阵  $A_h$ 。其中,  $A \in R^{H \times N \times N}$  表示有  $H$  个头部的注意力权重矩阵,每个矩阵的大小为  $N \times N$ 。最后,利用 Hampel 算法对每个概率稀疏自注意力头部得到的注意力权重矩阵  $A_h$  进行处理,得到优化后的权重矩阵  $A'_h$ 。

$$A = \text{softmax} \left( \frac{\overline{QK^T}}{\sqrt{d_k}} \right) \quad (18)$$

$$\begin{cases} O_h = A'_h V_h \\ O = \text{concat}(O_1, O_2, \dots, O_H) \end{cases} \quad (19)$$

对多头概率稀疏注意力机制中第  $h$  个头部输出的权重矩阵  $A_h$  进行 Hampel 优化时,首先要根据计算得出的权重矩阵  $A_h$  设定相应的偏差阈值。然后,通过将该阈值与实际权重值进行细致对比,有效识别并削弱由离群点

引发的注意力权重偏差问题。最后,实现权重分布不均现象的校正,进而增强模型的性能和估计精度。Hampel 处理计算过程如下。

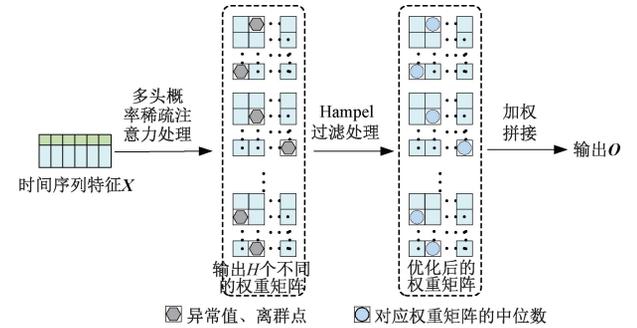


图 8 基于 Hampel 算法优化过程示意图

Fig. 8 Schematic diagram of the optimisation process based on Hampel algorithm

定义  $a_{ij}^h$  为权重矩阵  $A_h$  中的元素,其中  $h$  表示头部索引,  $i, j$  表示位置索引。权重矩阵偏差阈值的计算过程如下:首先,通过式(20)计算当前权重矩阵的中位数,根据式(21)计算相应的中位数绝对偏差(median absolute deviation, MAD)。然后通过式(22)来计算得出阈值(Threshold)。最后,通过式(23)进行判断。

$$\text{Median}(A_h) = \text{median}(\{a_{ij}^{(h)}\}) \quad (20)$$

$$\text{MAD}(A_h) = \text{median}(\{|a_{ij}^{(h)} - \text{Median}(A_h)|\}) \quad (21)$$

$$\text{Threshold} = k \times \text{MAD}(A_h) \quad (22)$$

式中:  $k$  是调整因子,该模型取  $k=2$ 。

$$|a_{ij}^{(h)} - \text{Median}(A_h)| \leq \text{Threshold}(A_h) \quad (23)$$

若满足式(23)的要求则说明该数值是可用的,反之将其替换为该权重矩阵的中位数。通过上述方法修正每个注意力头部  $h$  的注意力权重矩阵  $A_h$ , 得到优化后的权重矩阵  $A'_h$ 。最终,通过式(19)将权重矩阵  $A'_h$  与相应的值矩阵  $V_h$  进行加权,并将所有头部加权后的输出  $O_h$  进行拼接,得到最终的输出矩阵  $O$ 。通过以上方法,减少因异常值、离群点及不合理的权重分布等原因,引起的注意力偏差,使模型的稳定性和准确性得以提升。

### 3.2 基于 EKF-HInformer 的 SOC&SOH 联合估计模型

基于上述改进,本文设计了一种创新的 EKF-HInformer 模型,用于电动汽车动力电池 SOC 和 SOH 的联合估计。该模型能够有效克服传统时间序列预测模型在处理复杂、非线性数据时因梯度消失或爆炸问题而导致的训练稳定性下降、效率降低以及估计精度受限等挑战。其整体框架如图 9 所示,基于 EKF-HInformer 模型的 SOC 和 SOH 联合估计流程如下。

首先,将采集的动力电池数据(电压、电流和温度)进行 Z-score 归一化处理后,输入到经自适应增益因子改

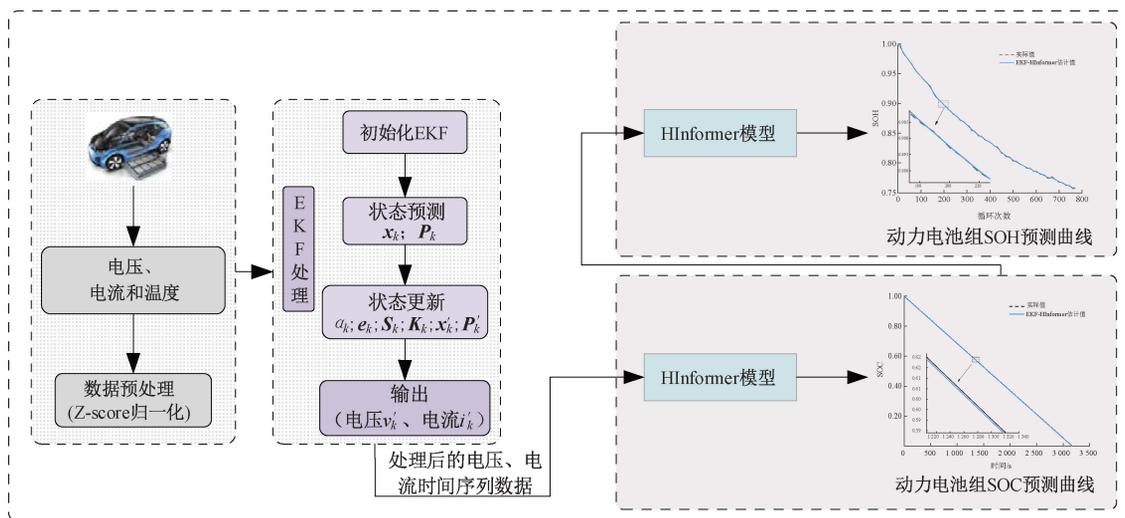


图9 EKF-HInformer 估计模型结构

Fig. 9 EKF-HInformer estimation model structure

进优化后的 EKF 中分析温度对电压、电流的影响,去除数据中的噪声和干扰。然后,将整理校准后的电压和电流数据输入到 HInformer 模型中,该模型中的 PPSA 经过 Hampel 算法优化,有效减少了信息丢失及头部间不平衡等问题对 PPSA 特征学习的影响,从而显著提升了模型的鲁棒性和泛化能力。最终,实现对动力电池 SOC 和 SOH 的联合估计。

在动力电池 SOC 和 SOH 的联合估计过程中,当进行 SOC 估计时,HInformer 模型的输入  $X$  为经过 EKF 处理后的电压和电流  $X=[v_1, i_1, v_2, i_2, \dots, v_n, i_n]$ 。在 SOH 估计阶段,考虑到 SOC 和 SOH 之间具有最大容量相关性,同时为减少充放电效率、温度变化等复杂因素对 SOH 估计的干扰,模型将通过估计得到的 SOC 变化曲线作为 HInformer 模型的输入,进而精确估算电池此次循环的 SOH 值。

## 4 实验验证分析

为验证本文 EKF-HInformer 模型在动力电池 SOC 和 SOH 估计中的有效性,本章节基于牛津大学电池驾驶循环数据集和马里兰大学电池数据集进行了实验验证。同时,为进一步证明模型的优越性,与传统 Informer、Transformer 和 LSTM 模型在相同条件下进行了对比实验。此外,为评估本文提出的 EKF 算法、HInformer 和 SOC&SOH 联合估计这 3 种改进点对估算结果的影响,设置了消融实验。

### 4.1 样本数据集

牛津大学电池驾驶循环数据集:牛津大学电池退化数据集包含 8 组容量为 740 mAh,额定电压为 4.2 V 的钴

酸锂离子电池,它们的编号分别是 Cell1, Cell2, ..., Cell8,所有电池均在 40 °C 的温度下进行测试。电池在恒定电流-电压的充电条件下进行充电,然后模拟电动汽车的驱动循环工况进行放电,直至达到 EOL (80%SOH);测量数据包含电压、电流、温度和放电容量。本文选用电池 Cell1、Cell6 作为测试集,把剩下的 6 组作为训练集。

马里兰大学电池数据集:该实验使用的是马里兰 CS2 Battery 电池数据集,电池型号有 CS2-35、CS2-36、CS2-37 和 CS2-38 共 4 种,电池材料有磷酸铁锂和氧化钴锂这两种,电池容量是 1 100 mAh。测试温度是 1 °C,标称电压是 3.7 V,充放电截止电压分别为 4.2 和 2.7 V。

将上述两种数据集均按 8 : 2 的比例划分为训练集和测试集,通过以上分配可以使其保持足够的训练集和测试集来评估模型的性能,避免出现过拟合的情况。

由于动力电池数据中的特征具有不同的分布,为帮助模型更有效的处理这些差异并提高网络的训练效率,对动力电池测量数据(电压、电流、温度)进行了 Z-score 归一化处理,即将原始数据转换为均值为 0、标准差为 1 的分布。计算如式(24)所示。

$$x_{normalized} = \frac{x - \mu}{\sigma} \quad (24)$$

式中: $x$  是原始数据; $\mu$  是该特征在数据集中的均值; $\sigma$  是该特征在数据集中的标准差; $x_{normalized}$  是归一化后的结果。

### 4.2 模型参数和评价标准

实验平台为 CPU (Intel Core i5-9300H CPU @ 2.40 Hz)、GPU (NVIDIA GeForce GTX 1650),编译平台为 Pycharm,编译器为 Pytorch。模型中的参数设置如表 1 所示。

表 1 HInformer 网络参数设置

Table 1 HInformer network parameter settings

参数	数值
注意力头数	12
模型维度	512
编码层数	2
解码层数	1
学习率	0.000 1
丢失率	0.05
批量大小	256
调整因子	2

选用均方根误差 (root mean square error, RMSE) 和最大绝对误差 (maximum absolute error, MAXE) 作为模型对 SOH 和 SOC 估算的评价指标。RMSE 表示估算结果的稳定性, 而 MAXE 体现了估算结果中的最大偏离程度。它们的定义如式(25)和(26)所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_r - S_i)^2} \quad (25)$$

$$MAXE = \max(|S_r - S_i|), 1 \leq i \leq N \quad (26)$$

式中:  $N$  是样本的总数;  $S_r$  是 SOC 或 SOH 的真实值;  $S_i$  是通过模型预测得出的 SOC 或 SOH 预测值。

### 4.3 EKF-HInformer 模型估计结果分析

对 EKF-HInformer 模型在两种不同公共数据集下的估计结果进行分析, 模型的参数如表 1 所示。通过图 10 可知当模型训练到 900 轮左右时, 模型的训练集与测试集的损失率几乎相同。这表明模型在训练数据和测试数据上都有良好的表现, 没有出现过拟合现象。

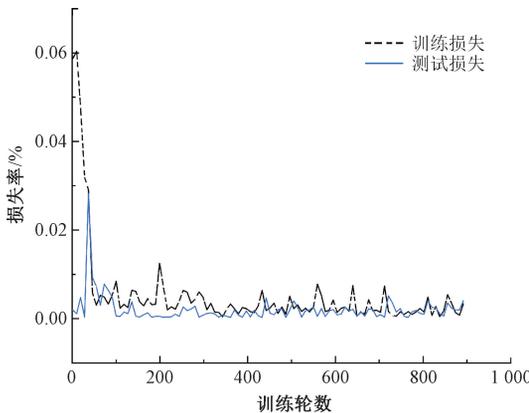
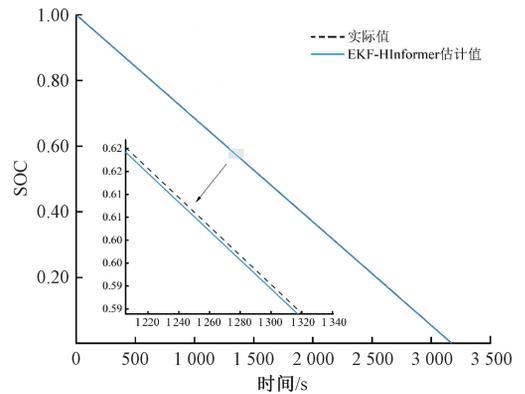


图 10 模型训练折损率

Fig. 10 Model training loss rate

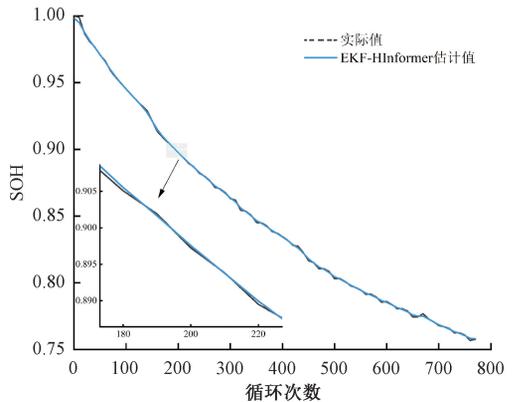
#### 1) 牛津大学电池驾驶循环数据集下的估计结果分析

EKF-HInformer 模型对牛津大学电池数据集 Cell1 SOC 和 SOH 的估计结果曲线如图 11 所示。



(a) Cell1 电池 SOC 的估计结果曲线

(a) Estimated result curve of Cell1 battery SOC



(b) Cell1 电池 SOH 的估计结果曲线

(b) Estimated resultant curves for Cell1 cell SOH

图 11 牛津大学电池数据集估计结果曲线

Fig. 11 Estimated result curves for the Oxford University battery dataset

观察图 11 可以看出, 模型的估计结果与真实值之间的差距极小。实验得出的决定系数  $R^2$ 、评价指标 RMSE 和 MAXE 的值如表 2 所示。

表 2 估计 Cell1 SOC&SOH 的评估指标

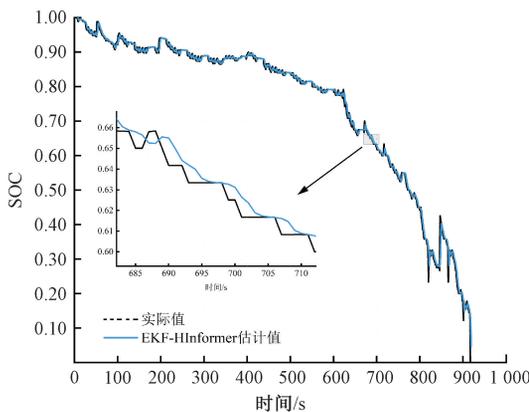
Table 2 Estimation of Cell1 SOC&SOH assessment metrics

Cell1	$R^2$	RMSE/%	MAXE/%
SOC	0.997 0	0.51	0.37
SOH	0.995 1	0.55	0.39

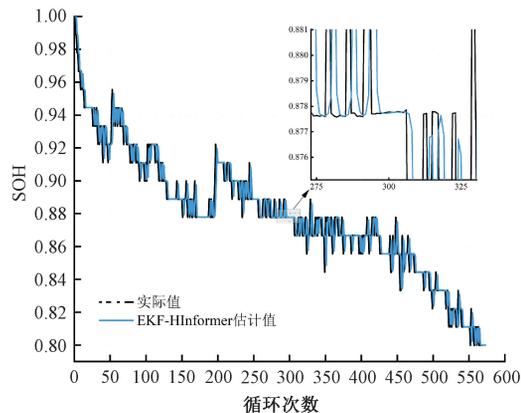
#### 2) 马里兰大学电池数据集的估计结果分析

将马里兰 CS2 Battery 电池数据集的 CS2-36、CS2-37 和 CS2-38 作为 EKF-HInformer 模型的训练集, 将 CS2-35 作为测试集。最终的估计结果曲线如图 12 所示。

观察图 12 可知, 模型的估计值与实际值之间的差异极为微小。实验得出的决定系数  $R^2$ 、评价指标 RMSE 和 MAXE 的值如表 3 所示。



(a) CS2-35 SOC 的估计结果曲线  
(a) CS2-35 estimated resulting curve for SOC



(b) CS2-35 SOH 的估计结果曲线  
(b) CS2-35 estimated resulting curve for SOH

图 12 马里兰大学电池数据集估计结果曲线

Fig. 12 Estimated result curves for the University of Maryland battery dataset

表 3 估计 CS2-35 SOC&SOH 的评估指标

Table 3 Estimated CS2-35 SOC&SOH assessment metrics

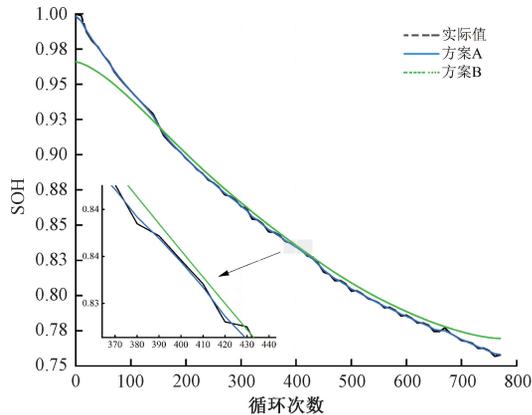
CS2-35	$R^2$	RMSE/%	MAXE/%
SOC	0.998 9	0.47	0.31
SOH	0.999 7	0.46	0.33

通过分析 EKF-HInformer 模型在两种不同数据集得出的估计结果曲线可知,该模型对不同电池型号以及不同温度条件下的电池数据,都有着非常高的估计精度。同时,根据实验最后得出的  $R^2$ 、RMSE 和 MAXE 的值可知,该模型具有不错的鲁棒性和泛化性,均体现了 EKF-HInformer 模型的优越性。

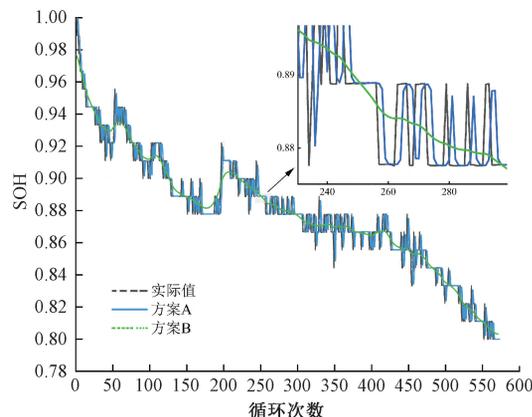
### 3) SOC 与 SOH 联合估计的有效性

SOC 的变化反映了电池在运行过程中的能量状态,而 SOH 则体现电池的衰减程度。考虑到 SOC 能实时反映电池瞬时性能,其变化模式与老化状态紧密相关,如随着电池逐渐老化其对应的 SOC 变化幅度将逐渐加快。因此,模型将估计所得 SOC 变化曲线作为表征老化特征

的重要输入,通过利用 SOC 所包含的动态信息,为 SOH 估计提供更加丰富和可靠的依据。为确保 SOC 数值与 SOH 数据在时间或循环维度上的对应关系,本研究在充放电循环关键节点记录 SOC,并将其与相应的 SOH 数据对齐,从而在模型训练或在线估计时实现 SOC 与 SOH 的匹配。为了验证该方法的有效性,对两个公共数据集按照相同的实验流程,分别在方案 A(本文方法)和方案 B(仅用电压、电流估计 SOH)下进行实验。通过 EKF-HInformer 模型估计的 SOH 结果曲线如图 13 所示。



(a) Cell1 估计结果曲线  
(a) Cell1 estimation result curve



(b) CS2-35 估计结果曲线  
(b) CS2-35 estimation result curve

图 13 EKF-HInformer 模型估计结果曲线

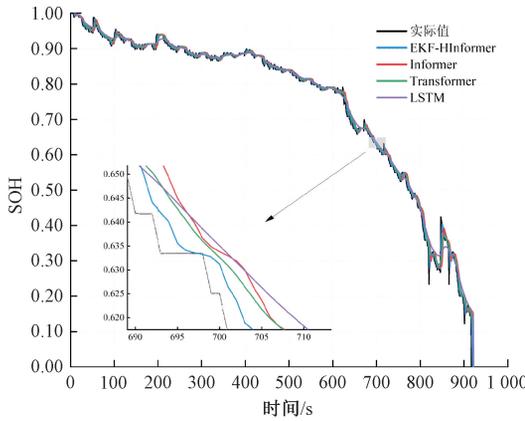
Fig. 13 EKF-HInformer model estimation result curve

由图 13 可知,当 SOC 作为估计 SOH 的输入特征时,SOH 的估计精度显著提升。因此,SOC 与 SOH 的联合估计是必要的。

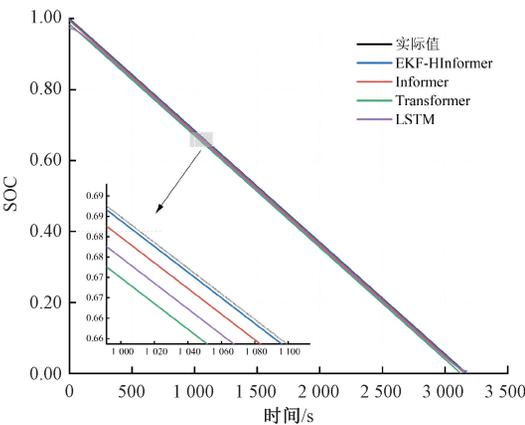
### 4.4 对比实验

为证明 EKF-HInformer 模型的优越性能,本节对 EKF-HInformer 模型与传统的 Informer、Transformer 和 LSTM 3 种模型进行了实验对比。实验所需数据均来自牛津大学电池数据集和马里兰大学 CS2 Battery 电池数据集。同样的将牛津大学电池数据集的 Cell1、Cell6,马里

兰大学 CS2 Battery 电池数据集的 CS2-35 作为测试集,把其他数据作为训练集。不同模型估计 SOC 和 SOH 的结果曲线,分别如图 14 和 15 所示。由图 14 和 15 可知, EKF-HInformer 模型在不同条件下的估计结果均要优于以上提到的 3 种模型。



(a) 电池CS2-35的SOC估计结果曲线  
(a) SOC estimation result curve of battery CS2-35



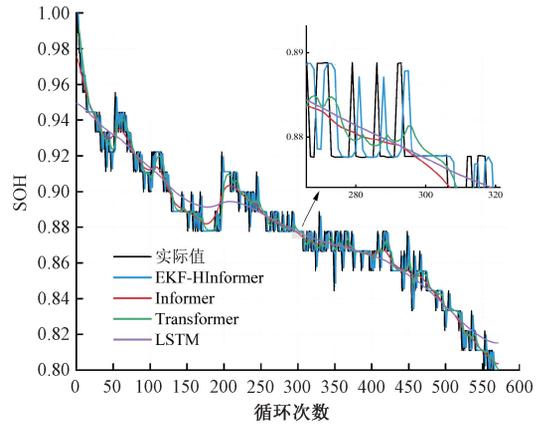
(b) 电池Cell1的SOC估计结果曲线  
(b) SOC estimation result curve for battery Cell1

图 14 不同模型对 SOC 的估计结果曲线对比

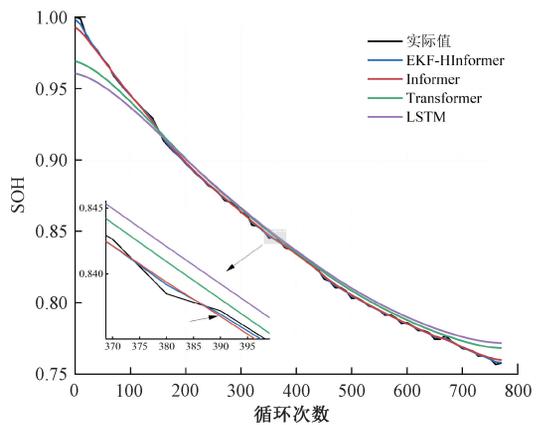
Fig. 14 Comparison of the estimation result curves of SOC by different models

为了更好的展示 EKF-HInformer 模型在鲁棒性和准确性方面的优势,将上述 4 种模型在估计后的  $R^2$ 、RMSE 和 MAXE 值分别记录并进行对比,结果如图 16 所示。观察图 16(a)可知, EKF-HInformer 模型在两种不同数据集下的估计精度均高于 0.995,且明显高于其他 3 种模型。此外,对比图 16(b)和(c)可知, EKF-HInformer 模型的 RMSE 和 MAXE 明显低于其他 3 种对照模型。

以马里兰大学 CS2-35 号电池 SOC 估计得出的评价指标为例进行详细说明。观察图 16(a)可知 EKF-HInformer 模型的  $R^2$  为 0.998,相较于 Informer、Transformer 和 LSTM 模型估计精度分别提高了 10%、8% 和 12%。观察图 16(b)可知 EKF-HInformer 模型的



(a) 电池CS2-35的SOH估计结果曲线  
(a) SOH estimation result curve for battery CS2-35

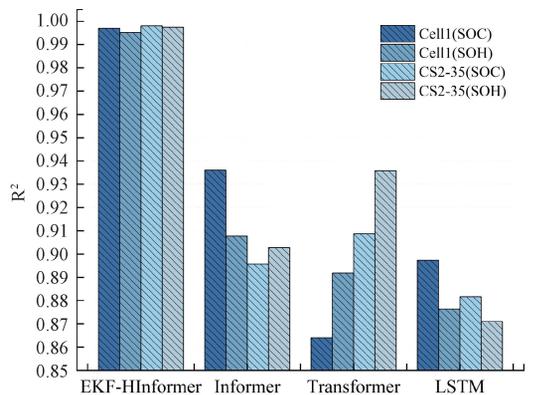


(b) 电池Cell1的SOH估计结果曲线  
(b) SOH estimation result curves for battery Cell1

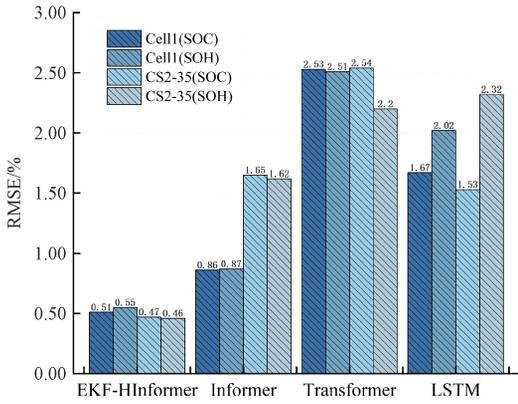
图 15 不同模型对 SOH 的估计结果曲线对比

Fig. 15 Comparison of curves of SOH estimation results from different models

RMSE 为 0.47%,相较于 Informer、Transformer 和 LSTM 模型 RMSE 分别减少 63%、76%和 60%。观察图 16(c)可知, EKF-HInformer 模型的 MAXE 为 0.31%,相较于 Informer、Transformer 和 LSTM 模型 MAXE 值分别减少

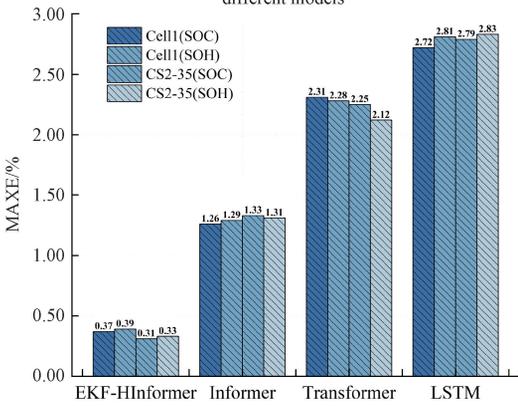


(a) 不同模型估计SOC&SOH的决定系数对比  
(a) Comparison of coefficients of determination of SOC&SOH estimated by different models



(b) 不同模型估计SOC&SOH的RMSE值对比

(b) Comparison of RMSE values of SOC&SOH estimated by different models



(c) 不同模型估计SOC&SOH的MAXE值对比

(c) Comparison of MAXE values of SOC&SOH estimated by different models

图 16 不同模型的评估指标对比

Fig. 16 Comparison of assessment metrics for different models

71%、82%和 69%。

综上所述,EKF-HInformer 模型在 SOH 和 SOC 的估计中均具有很高的精确性,相较于对比模型的 RMSE 和 MAXE 有着显著的减少。实验结果证明,EKF-HInformer 模型具有更优秀的估计精度、鲁棒性和泛化能力。

#### 4.5 消融实验

为了更加清晰的评估 EKF-HInformer 模型中各个改进方法对整体性能的影响。通过逐步移除或替换模型中的某些改进方法,然后观察模型性能的变化来验证每个改进点的有效性。各模型在 Cell1 和 CS2-35 数据集下 SOC 和 SOH 的估计评价指标结果如表 4 和 5 所示。

由表 4 可以看出,第 1 组数据代表传统 Informer 模型的估计效果。第 2 组通过引入 EKF 对电池数据进行处理,使得 Cell1 的 SOC 估计精度提升了 4.03%,RMSE 和 MAXE 分别下降了 28%和 17%;对于 Cell1 的 SOH 估计,精度也提升了 5.08%,RMSE 和 MAXE 则分别减少了 21%和 9%。这一显著提升凸显了处理模型输入数据的必要性。第 3 组实验采用了 Hampel 算法,与 Informer 模型相比,Cell1 SOC 的估计精度小幅提升了 0.72%,RMSE 和 MAXE 分别降低了 21%和 2%;Cell1 SOH 的估计精度增加了 1.26%。RMSE 和 MAXE 分别减少了 24%和 5%。这一结果表明,针对注意力机制的优化亦能有效提升模型性能,验证了其必要性。第 4 组实验呈现了 Informer 模型结合 EKF 与 Hampel 算法的估计成果,该模型的各项评价指标均展现出了模型的优越性。对比表 4 可知,若去除其中一个改进方法,均会导致模型性能的明显下降,因此综合优化改进方法在提升模型的估计性能中是

表 4 Cell1 消融实验结果

Table 4 Ablation experiment results of Cell1

(%)

模型	EKF	Hampel	SOC			SOH		
			$R^2$	RMSE	MAXE	$R^2$	RMSE	MAXE
Informer			93.61	0.86	1.26	90.76	0.87	1.29
EKF-Informer	✓		97.64	0.62	1.05	95.84	0.69	1.18
HInformer		✓	94.33	0.68	1.24	92.02	0.66	1.22
EKF-HInformer(本文)	✓	✓	<b>99.7</b>	<b>0.51</b>	<b>0.37</b>	<b>99.51</b>	<b>0.55</b>	<b>0.39</b>

表 5 CS2-35 消融实验结果

Table 5 Ablation experiment results of CS2-35

模型	EKF	Hampel	SOC			SOH		
			$R^2$	RMSE	MAXE	$R^2$	RMSE	MAXE
Informer			89.57	1.65	1.33	90.27	1.62	1.31
EKF-Informer	✓		98.28	0.63	1.01	96.61	0.65	1.15
HInformer		✓	93.21	0.71	1.29	94.63	0.83	1.23
EKF-HInformer(本文)	✓	✓	<b>99.89</b>	<b>0.47</b>	<b>0.31</b>	<b>99.97</b>	<b>0.46</b>	<b>0.33</b>

不可或缺的。

## 5 结 论

为了提高电动汽车 BMS 估计 SOC&SOH 的精确度,本文提出了一种基于 EKF-HInformer 模型的联合估计方法。该方法通过调整自适应增益因子提高 EKF 处理电池数据的性能,使用 Hampel 算法增强 Informer 模型中 PPSA 的特征学习能力,并将 SOC 估计所得曲线作为 SOH 估计时的输入特征,减少充放电效率和内阻变化带来的误差。在公共电池数据集上的对比实验表明,该模型在 SOC 和 SOH 联合估计任务中表现出了优越的性能,其 SOC 与 SOH 估计精度均超 99.5%, $RMSE < 1\%$ , $MAXE < 0.5\%$ 。消融实验结果表明,数据滤波、模型优化和耦合关系的利用对提升模型的鲁棒性和准确性具有显著作用。考虑到 SOH 在电池老化加剧时能为 SOC 估计提供更可靠的基础,未来计划将 SOH 估计结果引入 SOC 估计模型,以减少电池老化对 SOC 估计的影响,从而为电动汽车 BMS 的高效运行提供更为坚实的支持。

## 参考文献

- [ 1 ] 彭自然,王顺豪,肖伸平,等. 一种精确估算电动汽车动力电池 SOC&SOH 的循环门控模型[J]. 电子测量与仪器学报,2024,38(9):11-23.  
PENG Z R, WANG SH H, XIAO SH P, et al. Cycle gating model for accurate estimation of SOC&SOH of power battery in electric vehicles [ J ]. Journal of Electronic Measurement and Instrumentation, 2024, 38(9):11-23.
- [ 2 ] ZHAO L H, QIN P L. Accurate SOC prediction and monitoring of each cell in a battery pack considering various influencing factors [ J ]. IEEE Transactions on Industrial Electronics, 2023,70(1):1025-1035.
- [ 3 ] 赵轩,李美莹,余强,等. 电动汽车动力锂电池状态估计综述[J]. 中国公路学报,2023,36(6):254-283.  
ZHAO X, LI M Y, YU Q, et al. State estimation of power lithium batteries for electric vehicles: A review[J]. China Journal of Highway and Transport, 2023, 36 ( 6 ) : 254-283.
- [ 4 ] 杨梦洁,杨爱军,叶奕君,等. 基于气体分析的锂离子电池热失控早期预警研究进展[J]. 电工技术学报,2023,38(17):4507-4538.  
YANG M J, YANG AI J, YE Y J, et al. Research progress on early warning of thermal runaway of li-ion batteries based on gas analysis[J]. Transactions of China Electrotechnical Society, 2023,38(17):4507-4538.
- [ 5 ] 汪宇航,黄海宏,王海欣,等. 基于荷电状态差异的退役电池健康状态快速估计研究[J]. 仪器仪表学报,2023,44(12):55-68.  
WANG Y H, HUANG H H, WANG H X et al. Research on fast estimation of the state of health of retired batteries based on the state of charge differences [ J ]. Chinese Journal of Scientific Instrument, 2023,44(12):55-68.
- [ 6 ] 丁同,傅晓锦. 基于改进粒子群优化算法和极限学习机的锂离子电池健康状态预测[J]. 国外电子测量技术,2023,42(5):163-173.  
DING T, FU X J. Improved particle swarm optimization and an extreme learning machine are used to predict the health state of lithium-ion batteries [ J ]. Foreign Electronic Measurement Technology, 2023, 42 ( 5 ) : 163-173.
- [ 7 ] 彭自然,王顺豪,肖伸平,等. 基于 KAInformer 的电动汽车动力电池 SOC&SOH 估算[J/OL]. 电工技术学报,1-17 [2025-01-07]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.241502>.  
PENG Z R, WANG SH H, XIAO SH P, et al. State of charge and state of health estimation of electric vehicle power battery based on KAInformer model [ J ]. Transactions of China Electrotechnical Society, 1-17 [ 2025-01-07 ]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.241502>.
- [ 8 ] MENG J H, MATTIA R, LUO G ZH, et al. An overview and comparison of online implementable SOC estimation methods for lithium-ion battery [ J ]. IEEE Transactions on Industry Applications, 2018,54(2):1583-1591.
- [ 9 ] HU X, JIANG J, CAO D, et al. Battery health prognosis for electric vehicles using sample entropy and sparse Bayesian predictive modeling [ J ]. IEEE Transactions on Industrial Electronics, 2015,63(4):2645-2656.
- [ 10 ] 高峰,贾建芳,元淑芳,等. 基于 GRU-UKF 的锂离子电池 SOC 估计方法研究[J]. 电子测量与仪器学报,2022,36(11):160-169.  
GAO F, JIA J F, YUAN SH F, et al. Research on SOC estimation method of lithium-ion battery based on GRU-UKF [ J ]. Journal of Electronic Measurement and Instrumentation, 2022,36(11):160-169.
- [ 11 ] 彭自然,许怀顺,肖伸平. 一种基于 CatBoost 优化的光伏阵列故障诊断模型[J]. 电子学报,2024,52(7):2418-2428.  
PENG Z R, XU H SH, XIAO SH P, et al. A CatBoost optimization-based fault diagnosis model for photovoltaic arrays [ J ]. Acta Electronica Sinica, 2024, 52 ( 7 ) : 2418-2428.
- [ 12 ] 朱博,刘雪芹,王宇琿,等. 基于 EMD-LSTM-Attention 的锂离子电池 SOC 预测[J/OL]. 电源学报,1-12 [2025-01-07]. <http://kns.cnki.net/kcms/detail/>

12. 1420. TM. 20240419. 1720. 008. html.
- ZHU B, LIU X Q, WANG Y H, et al. SOC prediction for Lithium battery based on the model of EMD-LSTM-attention[J/OL]. Journal of Power Supply, 1-12 [2025-01-07]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20240419.1720.008.html>.
- [13] 申江卫, 高承志, 舒星, 等. 基于迁移模型的锂离子电池宽温度全寿命 SOC 与可用容量联合估计[J]. 电工技术学报, 2023, 38(11): 3052-3063.
- SHEN J W, GAO CH ZH, SHU X, et al. Joint estimation of SOC and usable capacity of lithium-ion battery with wide temperature and full life based on migration model [J]. Transactions of China Electrotechnical Society, 2023, 38(11): 3052-3063.
- [14] CHE Y B, LIU Y SH, CHENG Z, et al. SOC and SOH identification method of Li-Ion battery based on SWPSO-DRNN [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2021, 9(4): 4050-4061.
- [15] 靳明旭, 陈嘉楠, 陈宇昊, 等. 基于 U-Net 结构的卷积神经网络锂离子电池 SOC 估算[J/OL]. 电源学报, 1-10 [2025-01-07]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20240325.1818.008.html>.
- JIN M X, CHEN J N, CHEN Y H, et al. Convolutional neural network based on U-Net structure for Lithium-ion battery SOC estimation [J/OL]. Journal of Power Supply: 1-10 [2025-01-07]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20240325.1818.008.html>.
- [16] XIONG R, CAO J Y, YU Q Q, et al. Critical review on the battery state of charge estimation methods for electric vehicles[J]. IEEE Access, 2018, 6: 1832-1843.
- [17] HANNAN M A, HOW D N T, LIPU M S H, et al. Deep learning approach towards accurate state of charge estimation for lithium-ion batteries using self supervised transformer model[J]. Scientific Reports, 2021, 11(1): 19541-19541.
- [18] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.
- [19] HE ZH G, NI X G, PAN CH F, et al. Full-process electric vehicles battery state of health estimation based on informer novel model[J]. Journal of Energy Storage, 2023, 72: 108626.
- [20] MA J H, DAN J P. Long-term structural state trend forecasting based on an FFT-informer model[J]. Applied Sciences, 2023, 13(4): 2553-2553.
- [21] 欧阳天成, 徐裴行, 叶今禄, 等. 数据采集异常下的车用动力电池状态监测与故障诊断[J]. 中国电机工程学报, 2023, 43(15): 6040-6050.
- OUYANG T CH, XU P X, YE J L, et al. States monitoring and fault diagnosis of vehicular power batteries under abnormal data acquisition[J]. Proceedings of the CSEE, 2023, 43(15): 6040-6050.
- [22] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和降噪自编码器-短时间记忆的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(1): 289-302.
- YIN J, LIU B, SUN G B, et al. Transfer learning denoising autoencoder-long short term memory for remaining useful life prediction of Li-ion batteries [J]. Transactions of China Electrotechnical Society, 2024, 39(1): 289-302.
- [23] 陈媛, 段文献, 何怡刚, 等. 带降噪自编码器的锂离子电池健康状态估计算法[J/OL]. 电工技术学报, 1-17 [2025-01-07]. <https://doi.org/10.19595/j.1000-6753.tces.231644>.
- CHEN Y, DUAN W W, HE Y G, et al. State of health estimation algorithm of lithium-ion battery with denoising autoencoder [J/OL]. Transactions of China Electrotechnical Society, 1-17 [2025-01-07]. <https://doi.org/10.19595/j.1000-6753.tces.231644>.

## 作者简介



**彭自然** (通信作者), 2004 年于中南大学获得学士学位, 2008 年于中南大学获得硕士学位, 2017 年于中南大学获得博士学位, 现为湖南工业大学副教授, 主要研究方向为人工智能、信号处理、智能检测仪表等。  
E-mail: pengziran@hut.edu.cn

**Peng Ziran** (Corresponding author), received his B. Sc. degree from Central South University in 2004, M. Sc. degree from Central South University in 2008, and Ph. D. degree from Central South University in 2017, respectively. Now he is an associate professor at Hunan University of Technology. His main research interests include Artificial Intelligence, Signal Processing, and Intelligent Detection Instrumentation etc.



**杨肖阳**, 2023 年于武夷学院获得学士学位, 现为湖南工业大学硕士研究生, 主要研究方向为电动汽车动力电池荷电状态和健康状态估算。  
E-mail: 2873633605@qq.com

**Yang Xiaoyang** received his B. Sc. degree from Wuyi College in 2023. Now he is a M. Sc. candidate at Hunan University of Technology. His main research interests include electric vehicle power battery state of charge and state of health estimation.