

DOI: 10.19650/j.cnki.cjsi.J2412415

# 基于BP神经网络与 $H_\infty$ 滤波的锂电池 SoH-SoC联合估计研究\*

钱伟<sup>1,2</sup>, 王亚丰<sup>1</sup>, 王晨<sup>1</sup>, 郭向伟<sup>1,2</sup>, 赵大中<sup>1</sup>

(1. 河南理工大学电气工程与自动化学院 焦作 454003; 2. 河南省煤矿装备智能检测与控制重点实验室 焦作 454003)

**摘要:** 锂电池健康状态 (SoH) 和荷电状态 (SoC) 的精确估计是新能源汽车安全运行的重要保障。针对 SoH-SoC 联合估计精度低、鲁棒性差的问题, 提出一种基于变学习率 BP 神经网络和自适应渐消扩展  $H_\infty$  滤波的 SoH-SoC 联合估计方法。首先, 提出一种基于单位充电电压差时间间隔的新型 SoH 特征参数; 其次, 通过设计新型变学习率 BP 神经网络, 提高传统 BP 网络误差收敛速度及缩短权值寻优时间; 最后, 通过设计新型自适应衰减因子对传统扩展  $H_\infty$  滤波误差协方差矩阵进行加权, 建立自适应渐消扩展  $H_\infty$  滤波算法, 减小陈旧量测值对估计结果的影响, 提高扩展  $H_\infty$  滤波的估计精度及鲁棒性。实验结果表明, 本文所提算法 SoH 估计误差小于 0.35%, SoC 估计误差小于 0.5%, 展现出较高的估计精度和鲁棒性。

**关键词:** 锂电池; 健康状态; 荷电状态; 神经网络; 自适应滤波

中图分类号: TM912 TH89

文献标识码: A

国家标准学科分类代码: 470.40

## Joint estimation of SoH-SoC for lithium battery based on BP neural network and $H_\infty$ filter

Qian Wei<sup>1,2</sup>, Wang Yafeng<sup>1</sup>, Wang Chen<sup>1</sup>, Guo Xiangwei<sup>1,2</sup>, Zhao Dazhong<sup>1</sup>

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China;  
2. Henan Key Laboratory of Intelligent Detection and Control of Coal Mine Equipment, Jiaozuo 454003, China)

**Abstract:** Accurate estimation of the lithium batteries' state of health (SoH) and state of charge (SoC) is an important guarantee for the safe operation of new energy vehicles. Aiming at the low accuracy and poor robustness problems of joint SoH-SoC estimation, a joint SoH-SoC estimation method based on BP neural network with variable learning rate and adaptive fading extended  $H_\infty$  filter is proposed. Firstly, a novel SoH feature parameter based on time interval of unit charging voltage difference is proposed. Secondly, the traditional BP neural network is improved by using a novel BP neural network with variable learning rate to improve the error convergence speed and shorten the weights optimization search time. Finally, by designing a new type of adaptive fading factor to weight the error covariance matrix of traditional extended  $H_\infty$  filter, an adaptive fading extended  $H_\infty$  filter algorithm is established to reduce the influence of stale measurement on the estimation results and correspondingly improve the estimation accuracy and robustness of filter. The experimental results show that the SoH and SoC estimation errors of the proposed algorithm are smaller than 0.35% and 0.5%, respectively, demonstrating the high estimation accuracy and robustness.

**Keywords:** lithium battery; state of health; state of charge; neural network; adaptive filter

## 0 引言

锂电池具有能量密度高、循环寿命长的优点, 成为新能源汽车动力电池的首选<sup>[1]</sup>。其作为典型的非线性系

统, 健康状态 (state of health, SoH) 及荷电状态 (state of charge, SoC) 不能直接测量, 只能通过数学方法进行估计<sup>[2-3]</sup>, 且估计过程相互耦合, SoH 和 SoC 的联合估计成为目前电池状态估计研究的热点。

常见的 SoH 估计方法<sup>[4-5]</sup>包括: 直接测量法、模型法、

收稿日期: 2024-01-20 Received Date: 2024-01-20

\* 基金项目: 国家自然科学基金项目 (62373137)、河南省高校重点科研项目 (23A470006) 资助

数据驱动法等。直接测量法是一种离线方法,该方法简单直观,但不能实时在线估计。模型法包括电化学模型和等效电路模型。基于电化学模型的方法模拟了电池在运行过程中发生的化学反应,需要求解复杂的偏微分方程,计算复杂且难度高;等效电路模型使用更少的输入,大大减少了随着时间推移需要学习的参数数量,但等效电路模型对随机噪声过于敏感,使得输出的 SoH 实时变化,而 SoH 是一个长时间尺度状态参数,通常在一个充放电周期内基本无变化,导致基于等效电路模型的 SoH 估计可靠性大大降低。

数据驱动法基于神经网络进行可测量电气量与 SoH 的映射,此类方法避免了基于模型的方法中模型不确定性和过程噪声对估计精度的影响,是一种适用性较强的 SoH 估计方法。

对于数据驱动方法,SoH 特征参数和神经网络结构的设计是影响该方法性能和适用性的关键。文献[6-7]重点对锂电池健康特征展开研究。其中,文献[6]首先基于电化学模型获取欧姆电阻等内部健康特征,然后通过直接测量的方法获取电压等外部健康特征;文献[7]除了以恒流恒压充电曲线设计健康特征,创新的引入等放电压间隔内的能量变化进一步表征 SoH。实验结果表明,上述方法均获得了较为理想的 SoH 估计精度,但其采用的健康特征类别较多,增加了神经网络的计算负荷,并且有些健康特征需要在特定条件下才能良好的映射 SoH。文献[8-9]基于容量增量和单位时间内的电压降设计健康特征。其中,文献[8]结合回归分析和曲线拟合建立 SoH 估计方法,虽然整体实现过程简单,但其只适用于恒流放电工况,而实际电池放电过程电流具有很强的随机性,限制了该方法的适用范围;文献[9]以开路电压计算电压降,而开路电压不能在线测量,同样限制了方法应用。

也有较多基于数据驱动的估计方法将研究重点放在神经网络结构的创新设计,对于锂电池这种强非线性系统,BP(back propagation)神经网络由于其极强的非线性映射能力被广泛应用。文献[10]基于传统 BP 神经网络对锂电池的 SoH 进行估计,传统 BP 神经网络的学习时间较长且迭代次数较多,网络搜索最优权值的效率较低。文献[11-12]基于改进粒子群优化(particle swarm optimization, PSO)的 BP 神经网络估计 SoH,该算法收敛速度快、精度高,但存在容易早熟收敛及后期迭代效率低的问题。文献[13-14]基于遗传算法对 BP 神经网络的权重和阈值进行优化,以克服 BP 神经网络容易陷入局部最优的缺陷,但对于样本数量少、分布不均匀场景,预测能力较差。

常见的 SoC 估计方法<sup>[15-16]</sup>有:开路电压法、库仑积分法、数据驱动法、模型法等。开路电压法是一种离线方

法,不能实时在线估计 SoC。库仑积分法通过电流对时间的积分以实时计算 SoC 的变化量,其对电流测量精度要求较高,且估计误差会随着时间推移逐渐累积。神经网络是数据驱动法的典型代表,可以通过自主学习进行复杂抽象的非线性系统求解,具有出色的拟合能力,但 SoC 是一个短时间尺度的状态参数,基于神经网络进行 SoC 估计不可避免的存在时延问题,影响即时估计精度。

模型法基于状态方程,通过不同类型的滤波器或观测器对状态参数 SoC 进行估计,可以尽可能减小测量噪声带来的估计误差,成为近年 SoC 估计研究的热点。常见的模型法<sup>[17-18]</sup>有:Kalman 滤波、 $H_{\infty}$ 滤波( $H$  infinity filter, HIF)、滑模观测器等。与其他模型法相比,HIF 在噪声特性未知、动力电池建模不精确等情况下具有更强的鲁棒性。文献[19]为了克服模型不确定性对 SoC 估计的影响,基于鲁棒控制理论,提出了  $H_{\infty}$  扩展卡尔曼滤波( $H_{\infty}$  extended Kalman filter, HEKF),该方法可以实现更快的收敛速度和更好的鲁棒性,但其并没有克服陈旧量测数据对估计结果的影响,估计精度有进一步提升的空间。文献[20-22]基于 HIF 算法分别对不同类型卡尔曼滤波的鲁棒性进行改善,但陈旧量测数据对估计结果的影响并未消除,迭代过程的累计误差可能使误差协方差矩阵负定,甚至造成滤波发散。文献[23]首先基于 PSO 算法对带遗忘因子最小二乘法的遗忘因子进行优化,以提高其收敛速度;其次,通过对传统  $H_{\infty}$  滤波噪声协方差进行更新以提高其估计精度。但其算法实现过程过于复杂,并且遗忘因子有效变化范围很小,利用 PSO 对最小二乘法遗忘因子进行优化的必要性有待进一步验证。

SoH-SoC 联合估计是将电池的 SoH 考虑进 SoC 估计过程,更加准确地实现 SoH 和 SoC 的同时估计。文献[24]提出了一种混沌萤火虫粒子滤波方法,通过将一组粒子混沌映射到不同的状态方程解空间来实现高精度的 SoH-SoC 联合估计。文献[25]采用无迹卡尔曼滤波估计电池的 SoC,采用最小电化学模型来描述电池内锂含量的分布,估计电池的 SoH。结果表明,SoH 的平均误差约为 2%。然而,文献[24-25]均是基于一阶迁移等效电路模型建立估计方法,由于微观参数表征不充分,其估计结果的精度及鲁棒性较差。文献[26-27]在分数阶模型的基础上,提出了一种基于无迹卡尔曼滤波的多尺度联合估计方法。根据测量参数的快时变和慢时变特性,双滤波器基于不同的时间尺度对 SoH-SoC 联合估计,虽然一定程度上提高了估计精度,但该方法采用分数阶模型表征电池电化学特征,导致模型计算量较大,影响 SoC 估计的实时性。文献[28]采用容积卡尔曼滤波和  $H_{\infty}$  滤波进行 SoH-SoC 联合估计,容积卡尔曼滤波估计 SoC 时仍未消除陈旧量测数据对估计结果的影响,并且计算量

较大,不利于系统集成。文献[29]首先通过自适应扩展卡尔曼滤波(adaptive extended Kalman filter, AEKF)估计 SoC,其次将解决粒子稀释问题的改进萤火虫算法与粒子滤波器(improved firefly algorithm optimized particle filter, IFA-PF)结合以估计 SoH。基于 IFA-PF 的 SoH-SoC 联合估计在实验中取得了较为理想的估计精度,但萤火虫算法终止阈值设计困难,且易波动,阈值过大或过小都会对估计结果造成影响。

由以上文献调查可知,较多文献开展 SoH-SoC 联合估计,从不同角度提高了估计精度及鲁棒性,但仍存在一些问题:

1) 基于数据驱动的方法比较适合于长时间尺度的 SoH 估计。基于数据驱动的方法中,较多文献基于恒流充电曲线获取 SoH 特征参数,这些方法往往需要较为完整或固定电压范围的充电数据<sup>[6-9]</sup>,但电池实际工作过程中,受工况影响,完整的充电数据很难获取,且充电开始及结束时对应的电压具有很强的随机性,导致上述方法应用时具有较大的局限性;另外,BP 网络应用于 SoH 估计时,通常使用梯度下降法作为其标准学习模式。在这种模式下,学习率是固定的,可能导致网络权值在寻优过程中围绕最优值产生震荡,从而使得整个寻优过程变得缓慢<sup>[10-14]</sup>。

2) 进行 SoC 估计时,HIF 能够有效提高噪声特性未知、电池建模不精确情况下 SoC 估计的鲁棒性,但对陈旧量测值对估计结果的影响考虑不足<sup>[19-23]</sup>,使得 HIF 吸收了所有过往的测量信息,造成滤波器稳态条件下跟踪能力差,进而导致估计精度低甚至滤波器发散。

基于上述问题,提出一种基于 BP 神经网络与 HIF 的锂电池 SoH-SoC 联合估计方法。首先,以不同倍率恒流充电曲线为基础,创新的将单位充电电压差对应的时间间隔作为健康特征,用以映射 SoH;其次,通过设计新型变学习率 BP 神经网络(variable learning rate BP neural network, VLR\_BPNN),建立健康特征与 SoH 的映射关系,实现 SoH 的高精度估计;最后,利用 SoH 估计结果提取电池容量进行考虑 SoH 的 SoC 估计,通过建立自适应渐消扩展 H<sub>∞</sub> 滤波(adaptive fading extended H infinity filter, AFE\_HIF)算法,减小陈旧量测值对估计结果的影响,提高估计精度。具体创新点为:

1) 基于单位充电电压差对应的时间间隔建立健康特征,网络模型输入量可以为任意恒流充电片段的电流及电压,对输入参数的限制条件少,应用方便;同时,电压电流可以直接测量,参数获取方便。

2) 针对 BP 神经网络标准学习模式学习率固定的问题,提出一种新型 VLR\_BPNN 神经网络,以提高 BP 神经网络误差收敛速度,缩短权值寻优时间。

3) 针对基于 HIF 的 SoC 估计,设计一种新型衰减因子,建立基于衰减因子的 AFE\_HIF 算法,在弱化陈旧测

量数据对估计结果影响的同时,强化现时观测数据的作用,提高估值精度和鲁棒性。

## 1 基于单位充电电压差时间间隔的 SoH 特征参数设计

首先获取完整的锂电池恒流充电曲线,其次基于充电曲线,创新的提取单位充电电压差对应的时间间隔作为健康特征,以实现 SoH 的精确映射。

### 1.1 锂电池恒流充电曲线获取

由于放电工况的随机性显著强于充电过程,参数不易获取,本文基于充电曲线设计新型健康特征。实验对象为日本松下公司生产的 18650 型三元锂电池,参数如表 1 所示。

表 1 锂电池参数

Table 1 Lithium battery parameters	
参数	数值
型号	NCR18650BD
充/放电截止电压/V	4.2/2.5
初始 SoH	0.96
标称电压/V	3.7
标称内阻/mΩ	22
标称容量/Ah	3.2

基于自主搭建的实验平台获取不同 SoH 的恒流充电曲线。实验平台如图 1 所示,由安装有控制软件的上位机、中位机、Neware 可编程电子负载和高低温试验箱组成。电池测试设备型号为 CT-4008T-5V6A-S1,测试精度小于 0.05%,最大电流上升时间为 1 ms,设定数据采样周期为 0.5 s。程控高低温试验箱型号为 BPH-060A,温度波动范围为 $\pm 0.5^{\circ}\text{C}$ ,用于为电池提供稳定的工作温度。



图 1 电池测试平台

Fig. 1 Battery test platform

为获取不同 SoH 条件下的恒流充电曲线,需要对锂电池进行循环老化实验。在 25℃ 环境下进行老化充放

电实验。恒流倍率分别为0.2 C、0.5 C、0.75 C和1 C,包含了锂电池常见工况对应的电流范围,实验步骤如图2所示。

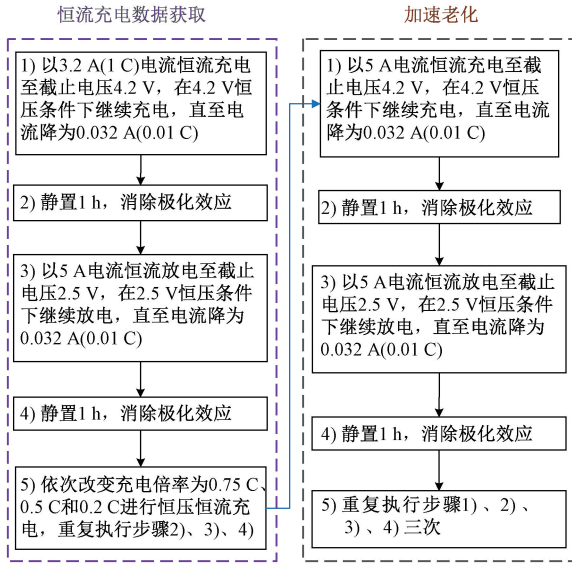


图2 实验步骤

Fig. 2 Experimental procedure

实验过程分为恒流充电数据获取和加速老化两部分。电池以4个恒流充电倍率各经历一次完整的充放电循环后,进行4次老化循环实验。两部分实验交替进行,前者用于获取完整的恒流充电曲线,后者则为了更快地获取实验数据。SoH定义如式(1)所示。

$$SoH = \frac{C_{\text{charge}} + C_{\text{discharge}}}{2C_{\text{rated}}} \quad (1)$$

式中: $C_{\text{charge}}$ 和 $C_{\text{discharge}}$ 分别为充电容量和放电容量; $C_{\text{rated}}$ 为电池出厂时最大可用容量。由于SoH较高或较低时,充放电曲线差异更大,其与健康特征的映射关系更明确,为表明文章内容的先进性,对电池SoH在0.96退化至0.88过程的老化数据进行研究,包含电流、电压、容量和温度等参数,共计204条充放电曲线。理论上,若新型估计方法在SoH为[0.88, 0.96]范围内具有理想的估计精度,则整个电池老化过程估计方法具有更高的精度。本文在SoH为[0.88, 0.96]范围内,以SoH基本相差0.01为间隔,各选取9条恒流充电曲线获取不同SoH条件下的健康特征,以1C恒流充电倍率为例的9条恒流充电曲线,如图3所示。

### 1.2 SoH 特征参数设计

基于恒流充电曲线,创新的提取单位充电电压差对应的时间间隔作为健康特征。取SoH为0.96、0.94、0.92、0.90和0.88时的恒流充电数据进行模型标定,恒流充电数据包括各倍率恒流充电条件下,每个电压值对应的相




图3 1C充电倍率下不同SoH的恒流充电曲线  
Fig. 3 Constant-current charging curves for different SoH at 1C charging current

对充电时刻。以各SoH条件下,不同倍率恒流充电数据建立健康特征,各SoH对应的健康特征数据集设计,如表2所示,将电池充电过程端电压为2.9 V的时刻定义为0时刻。

表2 不同SoH条件下数据集设计

Table 2 Dataset design under different SoH

电压/V	不同倍率对应的时刻			
	0.2C	0.5C	0.75C	1C
2.90	0	0	0	0
2.91	t1_1	t2_1	t3_1	t4_1
2.92	t1_2	t2_2	t3_2	t4_2
2.93	t1_3	t2_3	t3_3	t4_3
2.94	t1_4	t2_4	t3_4	t4_4
...	...	...	...	...
4.20	t1_130	t2_130	t3_130	t4_130

设计思路为:将锂电池电压从2.9 V~4.2 V以10 mV为单位等分,共131个电压标签。假设电池电压为2.9 V时,对应的时刻为初始时刻(即0时刻),当锂电池充电至2.91 V时,不同倍率条件下对应的时刻分别为t1\_1、t2\_1…。最终建立5个不同SoH条件下和不同充电倍率条件下电压值和各电压值对应的相对时刻值之间对应关系数据集。

为探究新型健康特征和目前常见的健康特征与SoH的相关程度,以0.2 C、0.5 C倍率对电池进行恒流恒压充电和恒流恒压放电,以获取完整的充放电曲线。提取常见的恒流充电时间(constant current charging time, CCCT)、恒流放电时间(constant current discharging time, CCDT)、单位放电时间的平均压降(average voltage difference for unit discharging time, AVD-UDT)、内阻(internal resistance, IR)和本文单位充电电压差时间间隔

(time interval for unit charging voltage difference, TI-UCVD)共5个特征用于研究其与SoH的相关性。采用皮尔逊系数作为特征相关性评价标准<sup>[13]</sup>,从18条0.2 C和0.5 C恒流充电倍率的老化曲线中提取健康特征,以探究每个特征与SoH的相关性。其中,AVD-UDT为放电期间总压降与总时间的比值;TI-UCVD以充电电压在3.50~3.70 V区间所对应的时间间隔为例。选取3.50~3.70 V电压片段的原因在于:3.50~3.70 V为锂电池充放电平台期,在此范围内电压变化比较平缓,若此区间能较好表征SoH,其他电压区间理论上表征SoH效果更好。针对每个特征参数 $X$ ,给定特征序列 $X = \{X_1, X_2, X_3, \dots, X_n\}$ 和SoH序列 $SoH = \{SoH_1, SoH_2, SoH_3, \dots, SoH_n\}$ ,其皮尔逊相关性公式为:

$$\rho_{X,Y} = \frac{\text{cov}(X, SoH)}{\sigma_X \sigma_Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(SoH_i - \overline{SoH})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (SoH_i - \overline{SoH})^2}} \quad (2)$$

式中: $X$ 表示电池的特征值; $n$ 为特征序列和SoH序列的长度; $\bar{X}$ 和 $\overline{SoH}$ 分别为特征序列和SoH序列的平均值; $\text{cov}(X, SoH)$ 表示特征和SoH之间的协方差; $\sigma_X$ 和 $\sigma_Y$ 分别表示特征序列和SoH序列的标准差。每个特征和SoH的皮尔逊系数如表3所示。

表3 不同健康特征与SoH的皮尔逊相关系数  
Table 3 Pearson correlation coefficient for different health features and SoH

参数	0.2 C	0.5 C
CCCT	0.984 5	0.979 8
CCDT	0.864 8	0.830 1
AVD-UDT	0.331 1	0.801 6
IR	0.962 5	0.985 5
TI-UCVD	<b>0.992 9</b>	<b>0.987 7</b>

皮尔逊系数越接近1,表明特征和SoH的相关性越高。由表3可知,TI-UCVD、CCCT和IR与SoH的相关性最高,而在电池储能系统实际充电过程中,由于在充电开始时刻,电池内部存有剩余电量,且电池可能在电压未达到充电截止电压时结束充电,导致在大多数工况下,获得完整恒流充电时间较为困难;另外,内阻对电池测量设备的精度要求较高,且易受温度影响,准确内阻的获取难度较大。而TI-UCVD可以通过不同的局部电压区间灵活获取,适用于复杂多变的环境,表3结果表明,TI-UCVD相比于其他常见健康特征具有与SoH相关性高且易获取的优势。本文以TI-UCVD作为SoH的特征参数,实现基

于随机恒流充电片段的锂电池SoH估计。

## 2 VLR\_BPNN 设计

为了提高BP神经网络的权值优化速度,本文提出了一种改进策略,在传统BP网络的基础上,通过设计新型变学习率的方法进行改进。具体步骤如下:

首先,设定网络预设精度 $e$ ,即网络训练的目标误差阈值;其次,计算网络的实际输出误差;最后,针对不同的节点间权值 $w_{j1}, w_{j2}, \dots, w_{jn}$ ,采用了不同的学习率 $\eta_1, \eta_2, \dots, \eta_n$ 进行差异化调整。这种策略能够更好地满足各权值寻优的不同需求,从而加速权值的寻优过程。

定义网络期望输出为 $Y$ ,实际输出记作 $y$ ,依据上述信息,可构建输出层的误差函数 $E(n)$ ,表达式如下:

$$E(n) = \frac{1}{2} \sum_{i=1}^i (Y - y)^2 \quad (3)$$

在求解最优网络权值的过程中,权值 $w_{ij}$ 的更新梯度依据误差对其的偏导数确定。依据式(4)和(5),对 $w_{ij}$ 进行更新获得其在 $n+1$ 次迭代的值。

$$\Delta w_{ij}(n) = -\eta_i(n) \frac{\partial E}{\partial w_{ij}} \quad (4)$$

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n) \quad (5)$$

在BP神经网络的迭代学习过程中,第 $n$ 次迭代时的连接权值和学习率分别为 $w_{ij}(n)$ 和 $\eta_i(n)$ 。式(4)中的负号表示沿着误差函数的负梯度方向进行权值的优化。完成第 $n$ 次迭代后,网络进入 $n+1$ 次迭代,此时新的学习率 $\eta_i(n+1)$ 由式(6)计算得出。

$$\eta_i(n+1) = k \cdot \eta_i(n) \quad (6)$$

变学习率的基本思想是,如果当前神经网络的误差减小,则增大学习率,加快收敛速度;如果神经网络的误差变大,则减小学习率,减小神经网络误差的震荡。综合考虑,设计 $k$ 的取值规则为:当 $E(n) < E(n-1)$ 时,取 $k \in (1.3, 1.7)$ ,保持原有的搜索方向;当 $E(n) > E(n-1)$ 时,取 $k \in (0.3, 0.7)$ ,搜索方向改为反方向;当 $E(n) \leq e$ 时,取 $k=0$ ,终止学习。VLR\_BPNN具体学习流程如图4所示。

## 3 基于VLR\_BPNN与AFE\_HIF的SoH-SoC联合估计

首先进行AFE-HIF算法设计,其次完成基于VLR\_BPNN与AFE\_HIF的联合估计方法设计。

### 3.1 AFE\_HIF 锂电池SoC算法建立

双极化(dual polarization, DP)等效电路模型能够在精度和速度方面取得良好的平衡<sup>[30]</sup>,采用DP模型进行AFE\_HIF算法设计。DP模型如图5所示,对应状态方程如式(7)所示。

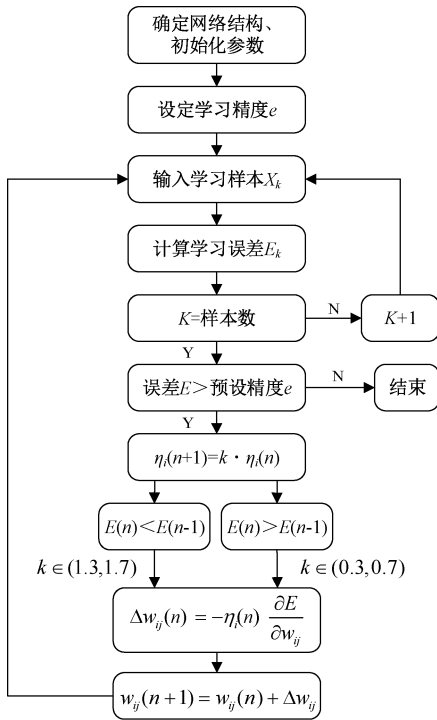


图4 变学习率BP神经网络学习流程

Fig. 4 Learning process of VLR\_BPNN




图5 DP 等效电路模型

Fig. 5 DP equivalent circuit model

$$\begin{cases} \dot{u}_p = \frac{i_L}{C_p} - \frac{u_p}{R_p C_p} \\ \dot{u}_s = \frac{i_L}{C_s} - \frac{u_s}{R_s C_s} \\ U_t = U_{oc} - u_p - u_s - i_L R \end{cases} \quad (7)$$

式中:  $i_L$  为电流;  $U_{oc}$  表示电池开路电压, 其为 SoC 的函数;  $R$  为欧姆电阻;  $R_p$ 、 $C_p$  分别为电化学极化电阻和电容;  $R_s$ 、 $C_s$  为浓差极化电阻和电容;  $u_p$  和  $u_s$  分别为电化学极化电容  $C_p$  和浓差极化电容  $C_s$  的电压;  $U_t$  为端电压。对于模型参数辨识, 国内外已有较多文献研究, 本文基于文献[30]中方法对 DP 模型参数进行辨识, 辨识过程不再赘述。

首先设计新型衰减因子; 其次, 基于衰减因子完成 AFE\_HIF 的设计。通过在先验误差协方差矩阵中引入自适应衰减因子, 减少过往测量数据信息对估计结果的

影响, 实现 SoC 估计的强跟踪。

新息用  $\delta_k$  表示, 即:

$$\delta_k = y_k - g(\hat{x}_k |_{k-1}, u_k) = y_k - H_k \hat{x}_k |_{k-1} \quad (8)$$

式中:  $H_k$  为测量矩阵;  $\delta_k$  为滤波器实际观测向量  $y_k$  与用状态预测值  $\hat{x}_k |_{k-1}$  计算出的观测向量  $g(\hat{x}_k |_{k-1}, u_k)$  之差。新息协方差矩阵如式(9)所示。

$$V_k = E[\delta_k \delta_k^T] = E[(y_k - H_k \hat{x}_k |_{k-1}) \times$$

$$(y_k - H_k \hat{x}_k |_{k-1})^T] = H_k P_{k+1|k} H_k^T + R_k \quad (9)$$

式中:  $P_{k+1|k}$  为误差协方差,  $R_k$  为测量的噪声协方差。基于新息的历史数据由开窗估计法重新定义其自适应协方差为:

$$V_k^* = \frac{1}{M - 1} \sum_{i=k-M+1}^k \delta_i \delta_i^T \quad (10)$$

式中:  $V_k^*$  为新息实时估计协方差函数;  $M$  为开窗的大小; 表示新息历史数据的个数; 窗口大小的选择影响 SoC 的估计精度。

为了使 SoC 估计过程具有强跟踪性, 需要满足正交性原理<sup>[31]</sup>, 确保式(11)成立:

$$E[x_k - \hat{x}_k |_{k-1}] [x_k - \hat{x}_k |_{k-1}]^T = \min, E[\delta_{k+j}^T \delta_k] = 0 \quad (11)$$

式中:  $j=1, 2, 3, \dots$ 。传统扩展  $H_\infty$  滤波 (extended H infinity filter, E\_HIF) 性能要求协方差矩阵  $P_k$  取到最优值, 则新息序列在任何时候都保持相互正交, 即为最小值<sup>[32]</sup>。需要以下引理<sup>[23]</sup>: 式(12)的新息序列自相关矩阵方程在 E\_HIF 得到精确的系统状态估计值时成立。

$$E[\delta_{k+j}^T \delta_k] \approx H_{k+j} F_{k+j-1} (I - K_{k+j-1} H_{k+j-1}) \times F_{k+j-2} \times \dots \times (I - K_{k+1} H_{k+1}) F_k \times (P_{k+1|k} H_k^T - K_k V_k) \quad (12)$$

式中:  $F_k$  为状态矩阵,  $j=1, 2, 3, \dots$ 。由以上结论可知, 对于每一个  $j$  的取值, 式(13)都有  $S_k$ :

$$S_k = P_{k+1|k} H_k^T - K_k V_k \quad (13)$$

由以上引理可知: 为了保证 E\_HIF 在受到干扰时的鲁棒性, 需要满足新息函数的自相关函数值为 0。若能保证式(13)为零, 就能确保式(12)成立, 从而保证 E\_HIF 算法的强跟踪性。但在式(13)中,  $H_k$  不变, 且新息协方差矩阵的理论值  $V_k$  在模型建模不精确的情况下会偏离实际值。为避免上述情况发生, 将  $V_k$  等价替换为新息协方差矩阵的估计值  $V_k^*$ , 此时可以将  $S_k$  调整为  $S_k^*$ , 通过进一步将其近似等于 0, 以保证 E\_HIF 算法的强跟踪性, 如式(14)所示。

$$S_k^* = P_{k+1|k}^* H_k^T - K_k^* V_k^* \approx 0 \quad (14)$$

式中:  $P_{k+1|k}^*$ 、 $K_k^*$  分别为加权后的误差协方差与最优增益矩阵。为使得式(14)成立, 设衰减因子  $\lambda_k$ , 将  $\lambda_k$  与误差协方差矩阵相乘, 从而进行加权。当  $\lambda_k > 1$  时, 则增大了增益矩阵  $K_k$ , 增强了当前数据的比重, 提高了系统鲁

棒性。设计误差协方差矩阵加权方式如下:

$$P_{k|k-1} = \lambda_k (A_{k-1} P_{k-1} A_{k-1}^T + Q_{k-1}) \quad (15)$$

其中,  $\lambda_k$  与原协方差预测方程整体相乘, 相当于对整个协方差预测方程进行加权, 有助于增强实时数据对估计结果的影响。为简化  $\lambda_k$ , 定义  $V_k$  和  $V_k^*$  的关系为:

$$V_k^* = \alpha_k V_k \quad (16)$$

其中, 系数  $\alpha_k$  由式(17)得出:

$$\alpha_k = \max \left\{ 1, \frac{\text{tr}(V_k^*)}{\text{tr}(V_k)} \right\} \quad (17)$$

新的增益利用  $P_{k|k-1}^*$  和  $P_{k|k-1}$  可推导为:

$$K_k^* = P_{k|k-1}^* H_k^T V_k^{*-1} = \lambda_k P_{k|k-1} H_k^T \left( \frac{V_k^{-1}}{\alpha_k} \right) =$$

$$\frac{\lambda_k}{\alpha_k} (P_{k|k-1} H_k^T V_k^{-1}) = \frac{\lambda_k}{\alpha_k} K_k \quad (18)$$

展开式(18)可得:

$$\frac{\lambda_k}{\alpha_k} P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} = \lambda_k P_{k|k-1} H_k^T (H_k \lambda_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (19)$$

假定  $H_k^T$  为满秩, 则式(19)化简为:

$$\alpha_k V_k = \alpha_k (H_k P_{k|k-1} H_k^T + R_k) = \lambda_k H_k P_{k|k-1} H_k^T + R_k \quad (20)$$

从式(20)可知, 通过自适应衰减因子  $\lambda_k$  对先验误差协方差矩阵  $P_{k|k-1}$  进行加权, 不仅可以实现  $\alpha_k$  加权新息协方差矩阵  $V_k$ , 还可以补偿实现过程中动态过程的缺失。  $\alpha_k$  由式(17) 计算之后, 代入式(20) 两边求迹, 计算自适应衰减因子  $\lambda_k$ , 求解方式如式(21) 所示。

$$\lambda_k = \frac{\text{trace}(\alpha_k H_k P_{k|k-1} H_k^T + (\alpha_k - 1) R_k)}{\text{trace}(H_k P_{k|k-1} H_k^T)} \quad (21)$$

式(21)的方式要求  $H_k^T$  满秩, 但实际情况无法满足  $H_k^T$  满秩, 对式(20) 变形可得:

$$\alpha_k H_k P_{k|k-1} H_k^T = \lambda_k H_k P_{k|k-1} H_k^T + (1 - \alpha_k) R_k \quad (22)$$

由于  $\lambda_k \geq 1$ , 则  $\alpha_k \geq 1$ 。 本文所提 AFE\_HIF 算法通过加权先验误差协方差矩阵  $P_{k|k-1}$  来得到新息协方差矩阵, 与矩阵  $R_k$  无关。 在式(22) 中可以将  $R_k$  忽略并假设  $\lambda_k = \alpha_k$ , 用  $\alpha_k$  的计算式(17) 来求  $\lambda_k$  的值。

基于上述分析, AFE\_HIF 算法中的衰减因子计算简单, 方式简洁, 易于实现。 基于衰减因子, 设计基于加权误差协方差矩阵  $P_{k|k-1}$  的 AFE\_HIF 算法。 具体设计过程如图6 所示。

### 3.2 SoH-SoC 联合估计

准确地估计 SoH, 可保证锂电池全生命周期内的 SoC 估计精度。 首先, 通过实验获取完整的锂电池恒流充电曲线, 提取 TI-UCVD 作为健康特征, 以模拟随机恒流充电片段; 其次, 建立 VLR\_BPNN 对 BP 网络传统的学习模式进行改进, 建立 TI-UCVD 和 SoH 的映射关系; 最后, 利

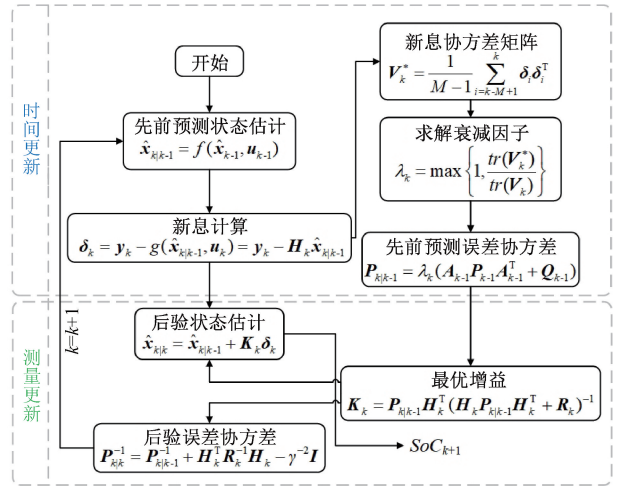


图6 AFE\_HIF 算法流程

Fig. 6 Flowchart of AFE\_HIF algorithm

用 SoH 对 SoC 估计过程中的容量  $C_n$  进行修正, 基于新型 AFE\_HIF 算法估计 SoC。 具体联合估计流程如图7 所示。

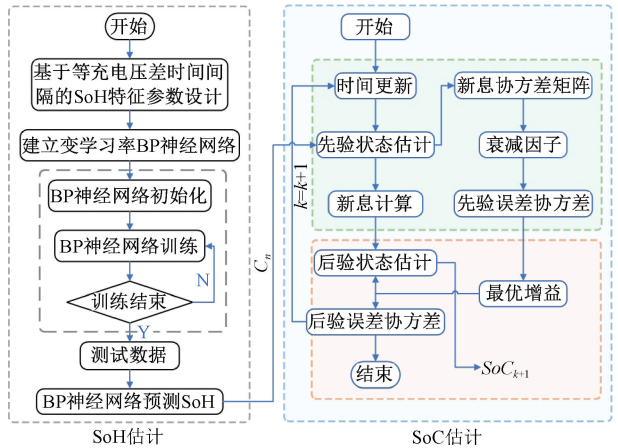


图7 锂电池 SoH-SoC 联合估计流程

Fig. 7 Joint estimation of SoH-SoC for lithium battery

## 4 新型估计方法有效性及先进性讨论

采用平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean square error, RMSE) 对 SoH-SoC 联合估计模型的预测性能进行评估。

### 4.1 新型估计方法有效性验证

#### 1) SoH 估计精度验证

为验证新型估计方法在整个数据集 SoH 范围内的估计效果, 基于 0.2 C、0.5 C、0.75 C 和 1 C 这 4 个倍率, 使用其中 3 个倍率数据对模型训练, 剩余的 1 个倍率用作测试。 首先, 选取充电倍率为 0.75 C 的数据作为模型测

试集;其次,针对标定区间长度为0.2 V(短充电区间)、0.5 V(中等充电区间)和0.8 V(长充电区间)的3个电压区间长度各选取3个电压片段,对所提 SoH 估计方法进行验证,并和传统的 BPNN 算法进行对比,其中第2节中网络预设精度  $e$  设置为0.015。所选取的电压片段和验证结果分别如表4和图8所示,图8(a)中每个预测值为9个电压区间所得预测值的平均值。估计误差如表5所示。

表4 不同区间长度的电压片段

Table 4 Voltage segments with different lengths

区间长度	电压区间
0.2	3.30~3.50, 3.50~3.70, 3.80~4.00
0.5	3.20~3.70, 3.40~3.90, 3.50~4.00
0.8	3.00~3.80, 3.20~4.00, 3.30~4.10

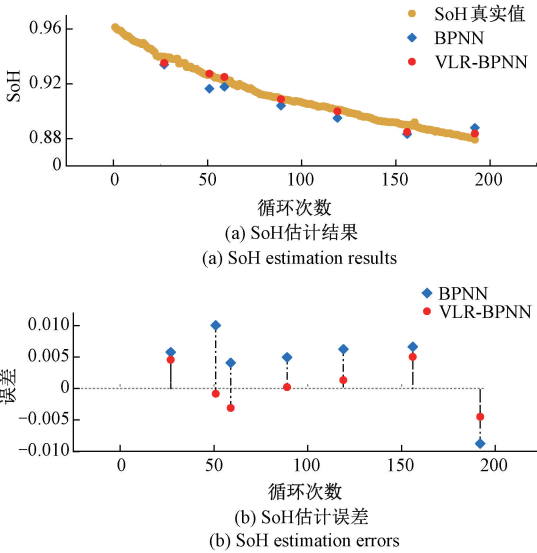


图8 SoH 估计结果及误差

Fig. 8 SoH estimation results and errors

表5 SoH 的估计误差

Table 5 SoH estimation errors

估计算法	MAE/%	RMSE/%
BPNN	0.66	0.69
VLR-BPNN	0.28	0.33

由图8和表5可知,在不同长度的电压片段内,本文所提 VLR-BPNN 算法与 BPNN 算法相比,估计精度显著提高,其中 MAE 下降了 57.6%, RMSE 下降了 52.2%。这是由于本文所提算法采用不同学习率分别对不同节点之间的权值进行差异性调节,以满足不同权值的寻优要求,加快了权值寻优速度,进而提高了 SoH 估计精度。以上结果表明本文所提基于随机恒流充电片段的锂电池

SoH 估计方法在模型的通用性和估计精度上均能取得良好的表现。

2) SoC 估计精度验证

为验证 AFE\_HIF 算法的强跟踪性以及良好的估计精度,参考联合国欧洲经济委员会汽车法规 (economic commission for Europe, ECE) 工况和美国先进电池联盟设计的动态应力测试 (dynamic stress test, DST) 工况,经过适当比例缩小,设计本文模拟工况。工况如图9所示。电流大于0表示放电,小于0代表充电,工况包含了锂电池充电、放电、搁置的工作状态。工况电压电流数据由前述实验平台获取。

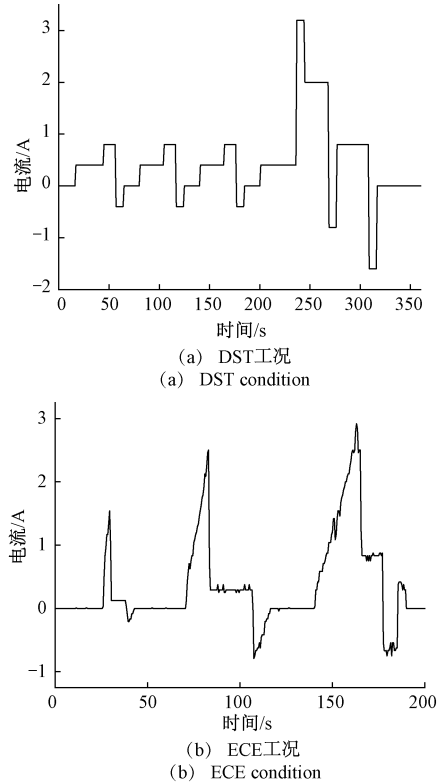


图9 模拟工况

Fig. 9 Simulated conditions

基于实测工况数据,在 MATLAB 中搭建仿真模型。其中,各参数初始值设置相同,如表6所示。

表6 状态参数初始值

Table 6 initial value of state parameters

参数	初始值
系统状态量 $x_k$	$[0.9 \ 0 \ 0]^T$
状态估计误差协方差矩阵 $P$	$[1 \ 0 \ 0; 0 \ 10^{-4} \ 0; 0 \ 0 \ 10^{-4}]$
系统白噪声协方差 $Q$	$[10^{-6} \ 0 \ 0; 0 \ 10^{-6} \ 0; 0 \ 0 \ 10^{-6}]$
测量白噪声协方差 $R$	1.37
性能边界 $\gamma$	0.5



另外,对于式(10)中开窗函数,窗口选择太大,会增大陈旧量测值对估计结果的影响,窗口选择太小,不足以刻画相应误差特征,综合考虑,本文选取  $M$  的值为 6。对比研究过程,为模拟初始 SoC 误差,将模型 SoC 初始值设置为 0.9。仿真过程不存在测量误差,将按时积分获得的 SoC 作为真实值。两种工况下 AFE\_HIF 和 E\_HIF 估计结果,如图 10、11 所示,MAE、RMSE 如表 7 所示。

由图 10、11 可知,AFE\_HIF 的收敛速度更快,这是由于 AFE\_HIF 算法能够通过衰减因子自适应减小陈旧量测

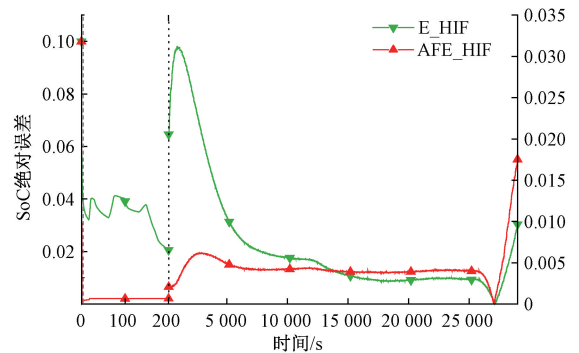




图 11 ECE 工况下 SoC 估计结果

Fig. 11 SoC estimation results under ECE condition



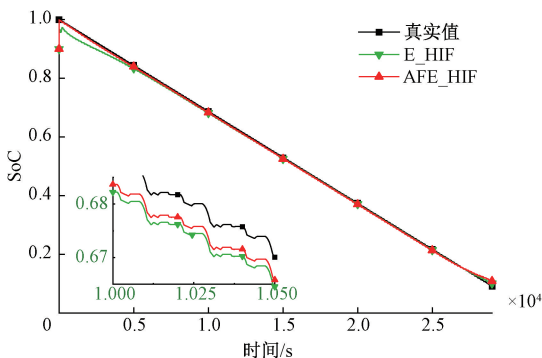
(a) SoC 估计结果  
(a) SoC estimation results



(b) SoC 估计绝对误差  
(b) Absolute errors of SoC estimation

图 10 DST 工况下 SoC 估计结果

Fig. 10 SoC estimation results under DST condition



(a) SoC 估计结果  
(a) SoC estimation results

表 7 不同工况估计误差

Table 7 Estimation errors under different conditions

估计算法		MAE/%	RMSE/%
E_HIF	DST	0.76	1.09
	ECE	0.74	1.06
AFE_HIF	DST	0.19	0.26
	ECE	0.45	0.49

值对估计结果的影响,提高算法的跟踪速度。由表 7 可知,本文所提 AFE\_HIF 算法与 E\_HIF 相比,DST 工况下,MAE 下降了 75.0%,RMSE 下降了 76.1%;ECE 工况下,MAE 下降了 39.2%,RMSE 下降了 53.8%。以上结果验证了所提算法在精度及鲁棒性方面的有效性及先进性。

#### 4.2 与同类方法相比先进性讨论

本节将基于 VLR\_BPNN 与 AFE\_HIF 的锂电池 SoH-SoC 联合估计算法与文献[29]和[33]中联合估计算法进行比较,对比模型关键参数设计如表 8 所示, $I_3$  表示 3 阶单位矩阵。SoH 估计结果如图 12 和表 9 所示。同样采用 DST 和 ECE 工况进行 SoC 估计精度验证初始 SoH 均设置为 0.96,估计结果如图 13、14 和表 10 所示。

表 8 模型参数对比

Table 8 Model parameter comparison

估计算法	$P$	$Q$	$R$	$\gamma$
AEKF <sup>[29]</sup>	$[1\ 0\ 0; 0\ 10^{-2}\ 0; 0\ 0\ 10^{-2}]$	$10^{-6} \times I_3$	1	
AEKF <sup>[33]</sup>	$[1\ 0\ 0; 0\ 10^{-2}\ 0; 0\ 0\ 10^{-2}]$	$10^{-6} \times I_3$	1	
AFE_HIF	$[1\ 0\ 0; 0\ 10^{-4}\ 0; 0\ 0\ 10^{-4}]$	$10^{-6} \times I_3$	1.37	0.5
估计算法	进化次数	种群规模	粒子数	$e$
IFA-PF <sup>[29]</sup>			100	
SSA-BPNN <sup>[33]</sup>	30	20		
VLR-BPNN				0.015

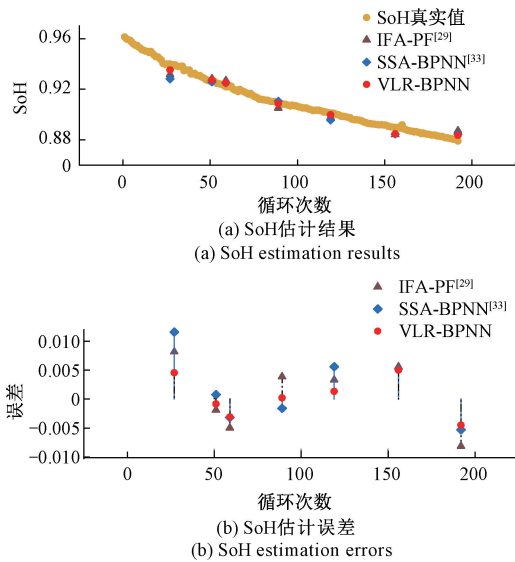


图 12 SoH 估计结果及误差

Fig. 12 SoH estimation results and errors

表 9 SoH 的估计误差

Table 9 SoH estimation errors

估计算法	MAE/%	RMSE/%
IFA-PF <sup>[29]</sup>	0.52	0.56
SSA-BPNN <sup>[33]</sup>	0.47	0.58
VLR-BPNN	0.28	0.33

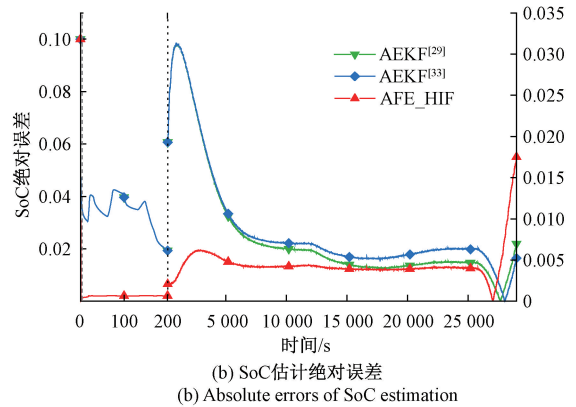
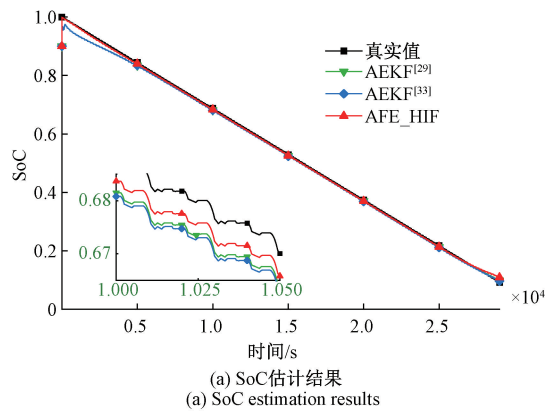


图 14 ECE 工况下 SoC 估计结果

Fig. 14 SoC estimation results under ECE condition

表 10 不同工况估计误差

Table 10 Estimation errors under different conditions

估计算法	工况	MAE/%	RMSE/%
AEKF <sup>[29]</sup>	DST	0.66	1.00
	ECE	0.81	1.09
AEKF <sup>[33]</sup>	DST	0.59	0.95
	ECE	0.89	1.14
AFE_HIF	DST	0.19	0.26
	ECE	0.45	0.49

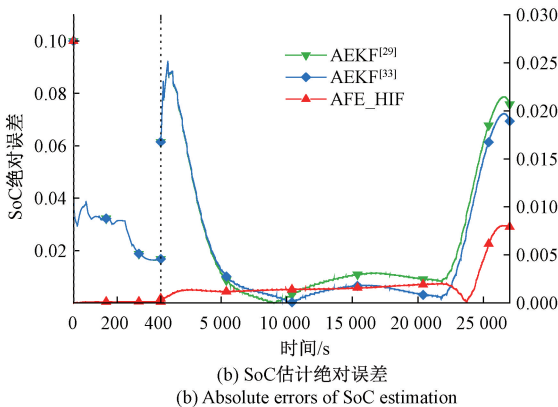
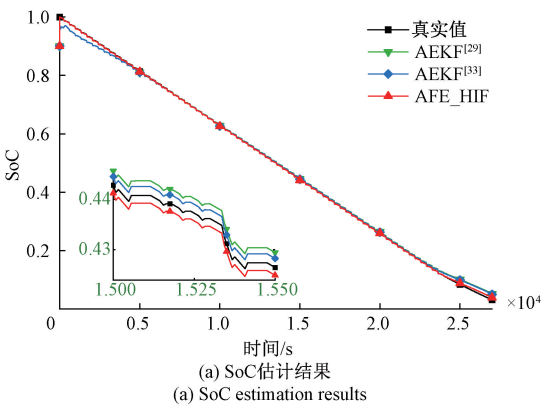


图 13 DST 工况下 SoC 估计结果

Fig. 13 SoC estimation results under DST condition

由图 12 和表 9 可知,本文 VLR-BPNN 模型,相比于文献[29]的 IFA-PF 模型和文献[33] SSA-BPNN 模型,MAE 分别下降了 46.2%、40.4%,RMSE 下降了 41.1%、43.1%。这是由于,文献[29]中萤火虫算法终止阈值设计困难,且易波动,阈值过大或过小都会对估计结果造成影响;文献[33]中麻雀优化算法的种群是随机初始化的,会造成初始种群分布不均,种群多样性减少、质量不高,从而导致估计精度下降。

本文及文献[29]和[33]均基于 SoH 估计值修正  $C_n$ ,进而对锂电池 SoC 进行估计。由图 13、14 可知,本文所提算法与改进的 AEKF 算法相比可以更好的跟踪真实

值。这是由于,AEKF<sup>[29]</sup>算法通过开窗函数弱化陈旧测量数据对当前估计结果影响,对过程噪声和测量噪声自适应更新,与本文基于加权误差协方差的自适应衰减因子相比,其跟踪真实值的效果较差;AEKF<sup>[33]</sup>算法虽然引入遗忘因子,但是陈旧量测值对估计结果的影响考虑不足,使得滤波器吸收了所有过往的测量数据信息,造成滤波器稳态条件下跟踪能力较差。由表10可得,本文所提AFE\_HIF算法与文献[29]和[33]中AEKF相比,在DST工况下,MAE分别下降了71.2%、67.8%,RMSE分别下降了74.0%、72.6%;在ECE工况下,MAE分别下降了44.4%、49.4%,RMSE分别下降了55.0%、57.0%。以上验证结果表明所提SoH-SoC联合估计算法在估计精度及鲁棒性方面的有效性及先进性。

## 5 结 论

针对锂电池状态估计,提出一种基于VLR\_BPNN和AFE\_HIF的SoH-SoC联合估计方法。首先,设计了一种易获取、相关性高的新型SoH特征参数,通过皮尔逊相关性系数验证了其SoH优异的映射关系。其次,提出一种新型变学习率BP神经网络,提高了传统BP神经网络误差收敛速度,缩短了权值寻优时间。最后,通过设计新型衰减因子,建立了一种AFE\_HIF算法,提高了传统HIF滤波的跟踪速度及估计精度。基于自主实验平台测试数据,通过搭建仿真模型,验证了所提SoH-SoC联合估计算法相比于同类型联合估计算法,在估计精度和鲁棒性方面的先进性。本文研究内容对于保障新能源汽车安全、稳定运行具有重要意义。未来的研究集中在将温度考虑进建模过程,进一步提高新型联合估计算法的精度及适用性。

## 参考文献

- [ 1 ] MAHESHWARI A, NAGESWARI S. Real-time state of charge estimation for electric vehicle power batteries using optimized filter[J]. *Energy*, 2022, 254: 124328-124342.
- [ 2 ] CHEN L P, GUO W L, LOPES A M, et al. State-of-charge estimation for lithium-ion batteries based on incommensurate fractional-order observer [ J ]. *Communications in Nonlinear Science and Numerical Simulation*, 2023, 118: 107059.
- [ 3 ] HUANG P, GU P W, KANG Y ZH, et al. The state of health estimation of lithium-ion batteries based on data-driven and model fusion method[J]. *Journal of Cleaner Production*, 2022, 366(15): 132742.
- [ 4 ] LIU Y SH, WANG L CH, LI D ZH, et al. State-of-health estimation of lithium-ion batteries based on electrochemical impedance spectroscopy: A review [ J ]. *Protection and Control of Modern Power Systems*, 2023, 8(1).
- [ 5 ] HOSSEININASAB S, LIN CH W, PISCHINGER S, et al. State-of-health estimation of lithium-ion batteries for electrified vehicles using a reduced-order electrochemical model [ J ]. *Journal of Energy Storage*, 2022, 52: 104684.
- [ 6 ] LI X N, JU L L, GENG G CH, et al. Data-driven state-of-health estimation for lithium-ion battery based on aging features[J]. *Energy*, 2023, 274: 127378.
- [ 7 ] GONG D, GAO Y, KOU Y, et al. State of health estimation for lithium-ion battery based on energy features[J]. *Energy*, 2022, 257(15): 124812.
- [ 8 ] PARK S W, LEE H, WON Y S. A novel aging parameter method for online estimation of lithium-ion battery states of charge and health[J]. *Journal of Energy Storage*, 2022, 48: 103987.
- [ 9 ] BIAN X L, WEI ZH B, LI W H, et al. State-of-health estimation of lithium-ion batteries by fusing an open circuit voltage model and incremental capacity analysis[J]. *IEEE Transactions on Power Electronics*, 2022, 37(2): 2226-2236.
- [ 10 ] WEN J P, CHEN X, LI X H, et al. SOH prediction of lithium battery based on IC curve feature and BP neural network[J]. *Energy*, 2022, 261: 125234.
- [ 11 ] MA Y, YAO M H, LIU H CH, et al. State of health estimation and remaining useful life prediction for lithium-ion batteries by improved particle swarm optimization-back propagation neural network[J]. *Journal of Energy Storage*, 2022, 52: 104750.
- [ 12 ] WU M Y, ZHONG Y M, WU J, et al. State of health estimation of the lithium-ion power battery based on the principal component analysis-particle swarm optimization-back propagation neural network [ J ]. *Energy*, 2023, 283(15): 129061.
- [ 13 ] SUN J, KAINZ J. State of health estimation for lithium-ion batteries based on current interrupt method and genetic algorithm optimized back propagation neural network[J]. *Journal of Power Sources*, 2024, 591(30): 233842.

- [14] ZHANG F, XING Z X, WU M H. State of health estimation for Li-ion battery using characteristic voltage intervals and genetic algorithm optimized back propagation neural network [J]. *Journal of Energy Storage*, 2023, 57: 106277.
- [15] YU Q Q, HUANG Y K, TANG A, et al. OCV-SOC-temperature relationship construction and state of charge estimation for a series-parallel lithium-ion battery pack[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(6): 6362-6371.
- [16] CHEN J X, ZHANG Y, WU J, et al. SOC estimation for lithium-ion battery using the LSTM-RNN with extended input and constrained output [J]. *Energy*, 2023, 262: 125375.
- [17] HE L, WANG Y Y, WEI Y J, et al. An adaptive central difference Kalman filter approach for state of charge estimation by fractional order model of lithium-ion battery[J]. *Energy*, 2022, 244: 122627.
- [18] XU CH, ZHANG E, YAN SH, et al. State of charge estimation for liquid metal battery based on an improved sliding mode observer [J]. *Journal of Energy Storage*, 2022, 45: 103701.
- [19] ZHAO L H, LIU ZH Y, JI G H. Lithium-ion battery state of charge estimation with model parameters adaptation using H-infinity, extended Kalman filter[J]. *Control Engineering Practice*, 2018, 81: 114-128.
- [20] ZHAO J B, MILI L. A decentralized H-infinity unscented Kalman filter for dynamic state estimation against uncertainties [J]. *IEEE Transactions on Smart Grid*, 2018, 10(5): 4870-4880.
- [21] ZHAO J B, MILI L. A theoretical framework of robust H-infinity unscented Kalman filter and its application to power system dynamic state estimation [J]. *IEEE Transactions on Signal Processing*, 2019, 67(10): 2734-2746.
- [22] NING ZH SH, DENG ZH W, LI J W, et al. Co-estimation of state of charge and state of health for 48 V battery system based on cubature Kalman filter and H-infinity [J]. *Journal of Energy Storage*, 2022, 56: 106052.
- [23] LIU Y Y, WANG SH L, XIE Y X, et al. A novel adaptive H-infinity filtering method for the accurate SOC estimation of lithium-ion batteries based on optimal forgetting factor selection [J]. *International journal of circuit theory and applications*, 2022, 50(10): 3372-3386.
- [24] QIAO J L, WANG SH L, YU C, et al. A chaotic firefly-Particle filtering method of dynamic migration modeling for the state-of-charge and state-of-health co-estimation of a lithium-ion battery performance [J]. *Energy*, 2023, 263: 126164.
- [25] XU ZH CH, WANG J, LUND P D, et al. Co-estimating the state of charge and health of lithium batteries through combining a minimalist electrochemical model and an equivalent circuit model [J]. *Energy*, 2022(1), 240: 122815.
- [26] YE L H, PENG D H, XUE D B, et al. Co-estimation of lithium-ion battery state-of-charge and state-of-health based on fractional-order model [J]. *Journal of Energy Storage*, 2023, 65: 107225.
- [27] MA L L, XU Y H, ZHANG H G, et al. Co-estimation of state of charge and state of health for lithium-ion batteries based on fractional-order model with multi-innovations unscented Kalman filter method [J]. *Journal of Energy Storage*, 2022, 52: 104904.
- [28] NING ZH SH, DENG ZH W, LI J W, et al. Co-estimation of state of charge and state of health for 48 V battery system based on cubature Kalman filter and H-infinity [J]. *Journal of Energy Storage*, 2022, 56: 106052.
- [29] OUYANG T CH, YE J L, XU P H, et al. Estimation of state-of-charge and state-of-health for lithium-ion battery based on improved firefly optimized particle filter [J]. *Journal of Energy Storage*, 2023, 68: 107733.
- [30] 郭向伟, 邢程, 司阳, 等. RLS 锂电池全工况自适应等效电路模型 [J]. *电工技术学报*, 2022, 37(16): 4029-4037.
- GUO X W, XING CH, SI Y, et al. RLS adaptive equivalent circuit model of lithium battery under full working condition [J]. *Transactions of China Electrotechnical Society*, 2022, 37(16): 4029-4037.
- [31] ZHUANG Y, WANG Z D, YU H Y, et al. A robust extended  $H_{\infty}$  filtering approach to multi-robot cooperative localization in dynamic indoor environments [J]. *Control Engineering Practice*, 2013, 21(7): 953-961.

- [32] FENG J Q, CAI F, YANG J, et al. An adaptive state of charge estimation method of lithium-ion battery based on residual constraint fading factor unscented Kalman filter[J]. IEEE Access, 2022, 10: 44549.
- [33] 赵靖英, 胡劲, 张雪辉, 等. 基于锂电池模型和分数阶理论的 SOC-SOH 联合估计[J]. 电工技术学报, 2023, 38(17): 4551-4563.
- ZHAO J Y, HU J, ZHANG X H, et al. Joint estimation of the SOC-SOH based on lithium battery model and fractional order theory [J]. Transactions of China Electrotechnical Society, 2023, 38(17): 4551-4563.

### 作者简介



钱伟(通信作者), 1999年于郑州大学获得学士学位, 2005年于东南大学获得硕士学位, 2009年于浙江大学获得博士学位。现为河南理工大学教授, 博士生导师, 主要研究方向为鲁棒控制、智能控制等。

E-mail: qwei@hpu.edu.cn

**Qian Wei** (Corresponding author) received his B. Sc. degree from Zhengzhou University in 1999, received his M. Sc. degree from Southeast University in 2005, received his Ph. D. degree from Zhejiang University in 2009. He is currently a professor and a Ph. D. advisor at Henan Polytechnic University of Technology. His main research interests include robust control and intelligent control, etc.



王亚丰, 2019年于南京师范大学获得学士学位。现于河南理工大学攻读硕士学位, 主要研究方向为车载动力电池的状态估计。

E-mail: 945800038@qq.com

**Wang Yafeng** received his B. Sc. degree from Nanjing Normal University in 2019. Now he is pursuing his M. Sc. degree at Henan Polytechnic University, and his main research interests include state estimation of vehicle-mounted power batteries.