

基于自适应动态滑动窗口的锂电池参数辨识 与SOC协同估计

朱业¹, 陈渊睿¹, 陈阳², 王镇霖³

(1. 华南理工大学 电力学院, 广东 广州 510641;

2. 哈尔滨工程大学 智能科学与工程学院, 黑龙江 哈尔滨 150000;

3. 华南农业大学 电子工程学院, 广东 广州 510642)

摘要: 锂电池的安全高效运行依赖于准确的荷电状态(SOC)估计, 但是传统的电池模型和SOC协同估计在噪声干扰下的鲁棒性和可靠性较差。针对噪声干扰下SOC协同估计问题, 首先对电池的最大可用容量和电池开路电压(OCV)特性进行分析, 研究了锂电池SOC—OCV的曲线特性。然后研究了噪声干扰下的在线模型参数辨识和SOC估计问题, 提出了基于自适应动态滑动窗口的双粒子群协同优化参数辨识(TCPSO)方法, 通过实验验证了所提方法的SOC估计最大误差小于1%, 表明所提方法可实现在线参数辨识, 并且在抗噪性能和SOC估计精度等方面均优于现有协同估计方法。

关键词: 荷电状态估计; 噪声干扰; 参数辨识; 双粒子群协同优化参数辨识

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqcd24637

Parameter Identification and SOC Estimation of Lithium Battery Based on Adaptive Dynamic Sliding Window

ZHU Ye¹, CHEN Yuanrui¹, CHEN Yang², WANG Zhenlin³

(1. School of Electric Power, South China University of Technology, Guangzhou 510641, Guangdong, China; 2. School of Intelligent Science and Engineering, Harbin Engineering University, Harbin 150000, Heilongjiang, China; 3. School of Electronic Engineering, South China Agricultural University, Guangzhou 510642, Guangdong, China)

Abstract: The safe and efficient operation of lithium batteries depends on accurate state of charge (SOC) estimation. However, the traditional battery model and SOC estimation have poor robustness and reliability under noise interference. Aiming at the problem of SOC cooperative estimation under noise interference, firstly, the maximum available capacity and open circuit voltage (OCV) characteristics of the battery were analyzed, and the curve characteristics of lithium battery SOC—OCV were studied. Then, the problem of online model parameter identification and SOC estimation under noise interference was studied, and a two-swarm cooperative particle swarm optimization (TCPSO) method based on adaptive dynamic sliding window was proposed. Experimental results show that the maximum SOC estimation error of the proposed method is less than 1%, which shows that the proposed method can realize online parameter identification, and it is superior to the existing collaborative estimation methods in terms of anti-noise performance and SOC estimation accuracy.

Key words: state of charge (SOC) estimation; noise interference; parameter identification; two-swarm cooperative particle swarm optimization (TCPSO)

电力能源作为国民经济的命脉, 为各国的经济和社会发展提供了必要保障和关键支撑。当前疫情仍然阻碍着全球经济的发展和复苏, 《BP世界能源年鉴2021》报告^[1]指出2020年全球能源

需求约下降4.5%。在电源侧, 电化学储能技术在近些年的发展态势迅猛, 其中又以锂离子电池装机量为主, 其占比高达92%。因此电化学储能, 尤其是锂离子电池, 将作为目前和未来储能发展

基金项目: 广东省自然科学基金-面上项目(2023A1515010184)

作者简介: 朱业(1996—), 男, 硕士, Email: zhuye_ele@163.com

的重要类型^[2]。在需求侧,电动汽车大规模推广进一步降低了二氧化碳的排放,实现了能源的高效利用。而目前在电动汽车中应用最为广泛的就锂离子电池^[3]。因此大力发展锂离子电池将使得能源供给侧和需求侧发生深刻变革,并进一步推动经济社会的绿色可持续发展。

电池状态估计主要包括SOC估计、健康状态(state of health, SOH)估计和功率状态(state of power, SOP)估计等。其中SOC用来表征电池当前可用容量情况^[4]。精确实时的SOC估计将有助于延长电池使用寿命,避免电池过充、过放,对实现安全高效可靠的电池实时运行管理具有极其重要的理论价值和现实意义。由于SOC是电池的内部状态无法直接获取,因此需要通过外部的电压和电流信号进行实时的SOC估计。对于SOC估计的方法主要包括安时积分法^[5-6]、特征参数估计方法、基于数据驱动的估计方法^[7]和基于模型的估计方法^[8]。

在实际应用中,终端电压和负载电流的测量不可避免地会包含噪声和电磁干扰,文献[9]采用递归总最小二乘法(recursive total least squares, RTLS)^[9],有效地避免了变量误差(errors in variables, EIV)噪声问题对模型辨识的影响。文献[10]利用带自适应遗忘的RTLS来平衡参数辨识的稳定性和参数跟踪的实时性。然而,这两种算法都依赖于已知比值的电压和电流噪声方差来实现无偏参数辨识;文献[11]提出了结合工具变量估计和双线性原理的噪声免疫模型参数辨识方法,但该参数辨识方法在工况初期需要考虑收敛性。然而上述三种方法均未探究输出误差(output error, OE)和输入误差(input error, IE)问题。在文献[12]中,辅助模型RLS有效地抑制了OE噪声问题对参数辨识的影响,但不能提高IE噪声问题下的参数辨识可靠性。现有的基于递推算法的噪声免疫参数辨识方法仅利用运行过程中的实时信号对参数进行修改。然而,通过在线递推算法获得的参数难以直接作为准确可靠的电池模型运行特性。

在上述背景下,本文首先对电池的最大可用容量和OCV特性进行分析,对比分析小电流OCV测试和增量电流OCV测试方法的理论精度,并通过增量电流OCV测试结果构建SOC—OCV的多项式拟合关系。然后研究了噪声干扰下的在线模型参数辨识和SOC估计问题。构建三类噪声

问题模型,并推导在噪声干扰下递推最小二乘法(recursive least squares, RLS)等参数辨识的偏置问题。为了免疫噪声干扰对在线参数辨识和SOC估计的影响,提出了基于自适应动态滑动窗口的TCPSO参数辨识方法,通过实验验证了所提方法的SOC估计最大误差小于1%。表明所提方法可实现在线参数辨识,并且在参数辨识抗噪性能和SOC估计精度等方面均优于现有协同估计方法。

1 锂离子电池SOC—OCV曲线特性

可靠精确的SOC—OCV关系可以有效提高模型的精度和SOC估计的准确性。然而在电池运行过程中,端电压不仅包含电池的开路电动势OCV,还包含由于欧姆内阻效应带来的欧姆内阻电压和由于极化效应带来的极化电压等。如何获取准确可靠的SOC—OCV关系逐渐成为行业广泛关注的焦点。目前被普遍认可的OCV测试方法主要分为小电流OCV测试和增量电流OCV测试两种。其中小电流测试OCV方法通过采用极小电流倍率的电流对电池进行充放电来尽可能地削弱内阻效应和极化效应,从而近似认为电池的端电压等价于电池的OCV。而增量电流OCV测试通过脉冲充放电过程充分搁置过程以获得当前SOC下的OCV值,最终通过插值方法确定SOC—OCV的关系。

1.1 OCV测试方法

小电流OCV测试实验在25℃恒温箱中进行,在测试过程中通过安时积分法获取SOC变化量,并和实时测量的端电压相对应,由此构建SOC—OCV关系曲线,并通过多项式拟合SOC—OCV关系。增量电流OCV测试通过对充放电后的电池进行充分的搁置以消除电池的内阻效应和极化效应从而得到电池的OCV值。测试中将搁置2h后的电池端电压作为电池的开路电动势OCV。实验中可以得到放电过程的11个OCV数据点和充电过程的11个OCV数据点。由此构建SOC—OCV多项式拟合曲线来表征电池的SOC—OCV关系。

综上所述,两种OCV测试方法,从测试时间成本来看,小电流测试方法所需时间预估为46h,而增量电流测试方法所需时间预估为42h。小电流测试虽大大抑制了电池的内阻效应和极化效应,但是由于时间的累积,极化效应等仍然在不断地累积

增大,因此在充放电过程的末段仍然具有较大的OCV测量误差。而增量电流OCV测试由于进行了2 h的充分搁置,可以认为电池极化电压已趋近于0,且不存在极化效应的累积。因此综合考虑测试时间成本和小电流测试潜在的误差以及对环境的依赖性,本文选择采用增量电流OCV测试方法来获得SOC—OCV关系,并应用于后续模型参数辨识和SOC估计的研究中。

1.2 SOC—OCV多项式拟合曲线方法

对充放电过程的两组OCV数据进行平均化处理^[13]可以进一步削弱迟滞效应对电池OCV的影响,本文对增量电流OCV测试得到的数据点进行平均化处理,并进行多项式拟合来确定SOC—OCV关系,其表达式为

$$U_{ocv} = f(SOC) = \sum_{q=0}^{poly} \alpha_q soc^q \quad (1)$$

式中: α_q 为多项式的系数, $q = 0, 1, 2, \dots, poly$, $poly$ 为多项式的阶数; U_{ocv} 为电池的OCV。

多项式的系数和阶数由SOC—OCV的实验结果拟合得到。为了避免多项式函数的过拟合,本文采用 $AdjR^2$ 这一指标来评价不同阶次的多项式拟合效果,其求解公式如下式所示:

$$\begin{cases} R^2 = \frac{\sum_{i=1}^{num} (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^{num} (y_i - \bar{y})^2} \\ AdjR^2 = 1 - (1 - R^2) \frac{num - 1}{num - (poly + 1)} \end{cases} \quad (2)$$

式中: y_i 为原始数据; \hat{y}_i 为拟合回归值; \bar{y} 为原始数据的均值; num 为原始数据样本个数; R^2 为决定系数,取值范围为[0, 1]。

R^2 越接近1,方程的变量对结果的解释性越强,方程对数据的拟合效果越好。而 $AdjR^2$ 在 R^2 的基础上进行了改进,可以消除因变量数增加对拟合判断结果的影响,避免了过拟合下 R^2 一味增长的弊端。

为了说明不同阶数多项式的SOC—OCV关系拟合效果,本文以马里兰大学电池公开数据库中INR18650—20R电池的增量电流OCV测试数据集^[14]为例,对比不同阶数多项式的拟合效果,可得表1结果。

以该增量电流OCV测试为例,通过对比分析不同阶次多项式拟合SOC—OCV的效果可以发现,当多项式阶数高于7次时,虽然决定系数 R^2 仍有小幅增长,但是 $AdjR^2$ 却呈现下降趋势。由此说明该电池的SOC—OCV关系对应的多项式阶数

高于7次时,多项式拟合出现了明显的过拟合现象。因此选择7次多项式来表征该电池的SOC—OCV关系,SOC—OCV的增量电流OCV实验结果和其拟合效果如图1所示。

表1 SOC—OCV关系多项式拟合结果

多项式阶数	R^2	$AdjR^2$
1	0.967 40	0.963 78
2	0.974 09	0.967 61
3	0.991 22	0.987 46
4	0.998 97	0.998 28
5	0.999 67	0.999 33
6	0.999 84	0.999 59
7	0.999 90	0.999 67
8	0.999 93	0.999 66
9	0.999 94	0.999 44




图1 增量电流OCV测试结果和最佳多项式拟合效果

Fig.1 Incremental current OCV test results and best polynomial fitting effect

2 噪声干扰下的锂电池参数辨识与SOC估计

2.1 噪声干扰下的锂电池参数辨识与SOC估计

为了实现锂电池模型参数的在线辨识,本文采用了一阶RC等效电路模型,并在递推算法中对其状态空间方程进行相应的变换,一阶等效电路模型的传递函数为

$$G(s) = \frac{U(s)}{I_b(s)} = R_0 + \frac{R_p}{R_p C_p s + 1} \quad (3)$$

同时,利用双线性变换法实现传递函数从S域到Z域的映射,其映射关系如下式所示:

$$s = \frac{2}{\Delta t} \frac{1 - z^{-1}}{1 + z^{-1}} \quad (4)$$

由此可以得到基于Z域的方程为

$$G(z) = \frac{a_1 + a_2 z^{-1}}{1 + a_3 z^{-1}} \quad (5)$$

其中

$$a_1 = \frac{-\Delta t + 2R_p C_p}{\Delta t + 2R_p C_p}$$

$$a_2 = \frac{(R_0 + R_p)\Delta t + 2R_0 R_p C_p}{\Delta t + 2R_p C_p}$$

$$a_3 = \frac{(R_0 + R_p)\Delta t - 2R_0 R_p C_p}{\Delta t + 2R_p C_p}$$

式中: a_1, a_2, a_3 为传递函数的系数。

相应的差分方程如下式:

$$U_k = U_{k-1} + a_{2,k} I_{b,k} + a_{3,k} I_{b,k-1} \quad (6)$$

将式(6)化简可得:

$$U_k = \boldsymbol{\varphi}_k^T \boldsymbol{\theta}_k \quad (7)$$

其中

$$\boldsymbol{\theta}_k = [a_{1,k} \quad a_{2,k} \quad a_{3,k}]^T$$

$$\boldsymbol{\varphi}_k = [U_{k-1} \quad I_{b,k} \quad I_{b,k-1}]^T$$

为了使得分析更具有一般性,本文以变量误差(errors in variables, EIV)问题为例推导分析噪声干扰对RLS等参数辨识的影响。包含噪声干扰的输入输出信号可以表示为

$$\begin{cases} \tilde{I}_{b,k} = I_{b,k} + \Delta I_{b,k} \\ \tilde{U}_k = \boldsymbol{\varphi}_k^T \boldsymbol{\theta}_k + \Delta U_k \end{cases} \quad (8)$$

式中: $I_{b,k}, \boldsymbol{\varphi}_k^T \boldsymbol{\theta}_k$ 分别为电流、电压输入信号; $\Delta I_{b,k}, \Delta U_k$ 分别为电流、电压噪声信号。

在本文中假设 $\Delta I_{b,k}$ 和 ΔU_k 为均值为0、方差分别为 σ_i^2 和 σ_v^2 的高斯白噪声。噪声信号保持和原始信号的独立性且电压、电流测量噪声也相互独立。由此式(8)可以修正为

$$\boldsymbol{\varphi}_k^T \boldsymbol{\theta}_k = \tilde{\boldsymbol{\varphi}}_k^T \boldsymbol{\theta}_k - \Delta \boldsymbol{\varphi}_k^T \boldsymbol{\theta}_k \quad (9)$$

其中

$$\tilde{\boldsymbol{\varphi}}_k^T = [\tilde{U}_{k-1} \quad \tilde{I}_{b,k} \quad \tilde{I}_{b,k-1}]^T$$

$$\Delta \boldsymbol{\varphi}_k = [\Delta U_{k-1} \quad \Delta I_{b,k} \quad \Delta I_{b,k-1}]^T$$

根据最小二乘原理可以构建如下方程:

$$\begin{cases} \hat{\boldsymbol{\theta}}_{LS} = (\tilde{\boldsymbol{\Phi}}_k^T \tilde{\boldsymbol{\Phi}}_k)^{-1} \tilde{\boldsymbol{\Phi}}_k^T \tilde{\boldsymbol{V}}_k \\ \tilde{\boldsymbol{V}}_k = \boldsymbol{V}_k + \Delta \boldsymbol{V}_k = \boldsymbol{\Phi}_k \boldsymbol{\theta} + \Delta \boldsymbol{V}_k \\ \tilde{\boldsymbol{\Phi}}_k = \boldsymbol{\Phi}_k + \Delta \tilde{\boldsymbol{\Phi}}_k \end{cases} \quad (10)$$

其中

$$\tilde{\boldsymbol{\Phi}}_k = [\tilde{\varphi}_k \quad \tilde{\varphi}_{k-1} \quad \cdots \quad \tilde{\varphi}_1]^T$$

$$\tilde{\boldsymbol{V}}_k = [\tilde{U}_k \quad \tilde{U}_{k-1} \quad \cdots \quad \tilde{U}_1]^T$$

参数向量的期望值表示为

$$E[\Delta \boldsymbol{\theta}] = E[\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_{LS}]$$

$$= [(\tilde{\boldsymbol{\Phi}}_k^T \tilde{\boldsymbol{\Phi}}_k)^{-1} \tilde{\boldsymbol{\Phi}}_k^T \tilde{\boldsymbol{\Phi}}_k \boldsymbol{\theta} - (\tilde{\boldsymbol{\Phi}}_k^T \tilde{\boldsymbol{\Phi}}_k)^{-1} \tilde{\boldsymbol{\Phi}}_k^T \tilde{\boldsymbol{V}}_k] \quad (11)$$

将式(11)化简可得:

$$E(\Delta \boldsymbol{\theta}) = (\tilde{\boldsymbol{\Phi}}_k^T \tilde{\boldsymbol{\Phi}}_k)^{-1} E[\tilde{\boldsymbol{\Phi}}_k^T (\tilde{\boldsymbol{\Phi}}_k \boldsymbol{\theta} - \tilde{\boldsymbol{V}}_k)] \quad (12)$$

$$E[\tilde{\boldsymbol{\Phi}}_k^T (\tilde{\boldsymbol{\Phi}}_k \boldsymbol{\theta} - \tilde{\boldsymbol{V}}_k)] = E[\tilde{\boldsymbol{\Phi}}_k^T (\boldsymbol{\Phi}_k + \Delta \boldsymbol{\Phi}_k) \boldsymbol{\theta} - (\boldsymbol{V}_k + \Delta \boldsymbol{V}_k)] = \boldsymbol{D} \boldsymbol{\theta} \quad (13)$$

其中, \boldsymbol{D} 在不同的噪声干扰问题下呈现不同的矩阵形式。在EIV问题中 $\boldsymbol{D}_{EIV} = \text{diag}\{\sigma_v^2 \quad \sigma_i^2 \quad \sigma_i^2\}$;在OE问题时由于电流噪声的影响被忽略,因此 $\boldsymbol{D}_{OE} = \text{diag}\{\sigma_v^2 \quad 0 \quad 0\}$;同理,在IE问题中 $\boldsymbol{D}_{IE} = \text{diag}\{0 \quad \sigma_i^2 \quad \sigma_i^2\}$ 。上述推导说明无论在哪一类噪声干扰下,RLS的参数辨识结果均存在偏置。由于带遗忘因子的递推最小二乘法(forgetting factor recursive least squares, FRLS)和RLS的差异仅存在于遗忘因子的设置,本质仍然为最小二乘法的递推形式,因此FRLS在噪声干扰下的参数辨识偏置影响和RLS类似。

2.2 具有噪声免疫能力的TCPSO适应度函数

为了提高参数辨识的精度和噪声免疫能力,本文定义TCPSO的适应度函数为

$$\varepsilon = RMSE(\boldsymbol{U}_b) = \sqrt{\frac{1}{W} \sum_{k=t-W}^t (\tilde{U}_{b,k} - \hat{U}_{b,k})^2} \quad (14)$$

式中: $\tilde{U}_{b,k}$ 为测量的端电压信号; W 为窗口大小; t 为当前时刻。

适应度函数根据模型预测电压均方根误差(root mean square error, RMSE)寻找参数辨识的最优解。为了分析所提适应度函数的噪声免疫能力,将式(14)改写成如下矩阵形式:

$$\varepsilon = \sqrt{\boldsymbol{\delta}^T \boldsymbol{\delta} / W} \quad (15)$$

其中

$$\boldsymbol{\delta}^T \boldsymbol{\delta} = (\tilde{\boldsymbol{U}}_b - \hat{\boldsymbol{U}}_b)^T (\tilde{\boldsymbol{U}}_b - \hat{\boldsymbol{U}}_b)$$

$$= \boldsymbol{\omega}^T \boldsymbol{\omega} + (\boldsymbol{U}_b - \hat{\boldsymbol{U}}_b)^T (\boldsymbol{U}_b - \hat{\boldsymbol{U}}_b) + 2\boldsymbol{\omega}^T \boldsymbol{U}_b - 2\boldsymbol{\omega}^T \hat{\boldsymbol{U}}_b \quad (16)$$

其中 $\boldsymbol{U}_b = [U_{b,t-W}, U_{b,t-W+1}, \dots, U_{b,t}]$

式中: \boldsymbol{U}_b 为在自适应动态滑动窗口(adaptive dynamic sliding window, ADSW)中的端电压时间序列向量; $\boldsymbol{\omega}$ 为均值为0的高斯白噪声向量,其向量长度和 \boldsymbol{U}_b 保持一致。

由于向量 $\boldsymbol{U}_b, \hat{\boldsymbol{U}}_b$ 和 $\boldsymbol{\omega}$ 互相独立,因此 $E(\boldsymbol{\omega}^T \boldsymbol{U}_b) = E(\boldsymbol{\omega}^T \hat{\boldsymbol{U}}_b) = 0$ 。当窗口尺度 W 增长后,式(14)可以进一步推导得:

$$\varepsilon = \sqrt{E(\boldsymbol{\delta}^T \boldsymbol{\delta})} = \sqrt{E(\boldsymbol{\omega}^T \boldsymbol{\omega}) + (\boldsymbol{U}_b - \hat{\boldsymbol{U}}_b)^T (\boldsymbol{U}_b - \hat{\boldsymbol{U}}_b)} \quad (17)$$

其中, $E(\boldsymbol{\omega}^T \boldsymbol{\omega})$ 是一个只和噪声方差相关的常数。 $(\boldsymbol{U}_b - \hat{\boldsymbol{U}}_b)^T (\boldsymbol{U}_b - \hat{\boldsymbol{U}}_b)$ 的值取决于模型参数辨识结果

的精度。从式(17)可得,随着数据量的增长, $E(\omega^T \omega)$ 的值在 ε 中的权重将逐渐降低,因此当数据量足够时 ε 的大小将取决于模型参数辨识精度,而几乎不受噪声干扰的影响。根据上述推导分析,本文选择将模型预测端电压的RMSE作为适应度函数在噪声干扰下可获得高精度的模型参数辨识结果。

2.3 TCPSO 参数辨识过程

TCPSO 是一种改进的粒子群算法,其采用双粒子群协同更新来寻找全局最优解。在TCPSO算法迭代寻优的过程中,从粒子群通过深度搜索局部最优位置来提升迭代寻优的收敛速度;主粒子群通过开发粒子群的全局多样性来确保迭代寻优的收敛精度^[15]。采用该方法可以有效均衡粒子群的收敛速度和收敛精度,因此本文选择该算法来进行参数辨识,这使得参数辨识结果可以快速收敛于全局最优解。本文设定TCPSO的辨识向量为

$$\theta_{TCPSO} = \{ R_0, R_p, e^{-\Delta U_r}, U_{p-} \} \quad (18)$$

式中: U_{p-} 为 $t-W$ 时刻的预测极化电压。

不同于离线参数辨识的参数辨识向量,在线工况下很少有长时间的静置过程,因此在不同时刻的极化电压也存在不确定性,因此需要将极化电压也作为参数辨识向量的变量之一参与参数寻优过程。经过尺度放缩确定TCPSO的4个变量的初始搜索空间为(0,1)。为了提升寻优收敛速度,TCPSO将粒子群分为从粒子群和主粒子群,其中从粒子群专注于探索当前区域的最优解,因此不再考虑粒子当前时刻的速度,其粒子的速度根据下式进行更新:

$$v_{ij}^S(d+1) = c_1^S r_1 (1-r_2) [x_{ij}^S(d) - x_{ij}^S(d)] + c_2^S (1-r_1) r_2 [gbest_j^S(d) - x_{ij}^S(d)] \quad (19)$$

主粒子群的目的是确保在迭代过程中具有粒子多样性以避免陷入局部最优解。因此主粒子群的速度具有较大的惯性以探索更大范围的区域,其速度更新公式如下:

$$v_{ij}^M(d+1) = \omega v_{ij}^M(d) + c_1^M r_1 (1-r_2) (1-r_3) \cdot [pbest_{ij}^M(d) - x_{ij}^M(d)] + c_2^M (1-r_1) r_2 (1-r_3) \cdot [gbest_j^S(d) - x_{ij}^M(d)] \quad (20)$$

两个粒子群的速度更新在粒子群算法的基础上进行了改进,其中新增学习因子 c_3 和(0,1)之间的独立随机数 r_3 。主粒子群和从粒子群分别用上标M和S来表示。

本文中TCPSO不再设置固定的迭代寻优次

数,而是将最大迭代次数限定为100次。当适应度函数结果趋近于收敛或迭代次数达到最大值时,结束迭代过程并输出参数辨识结果。TCPSO的主要过程如下:

- 1) 随机初始化全局空间或约束空间中所有粒子的位置和速度;
- 2) 对主粒子群和从粒子群中每个粒子的适应度值进行计算;
- 3) 求解在主粒子群中每个粒子的最佳历史位置 $pbest_{ij}^M$;
- 4) 求解最小适应度值对应的全局最优位置 $gbest$;
- 5) 求解从粒子群中适应度值对应的从粒子群最优位置 $gbest^S$;
- 6) 迭代计数 d 被初始化为0;
- 7) 更新从粒子群的速度和位置并更新 $gbest^S$;
- 8) 更新主粒子群的速度和位置并更新 $pbest_{ij}^M$ 和 $gbest$;
- 9) 迭代计数 $d = d + 1$;
- 10) 判断迭代终止条件,若满足则输出最佳优化结果,否则循环步骤7)~步骤9)。

2.4 双模块并行的自适应动态滑动窗口

在利用TCPSO进行参数辨识的过程中需要确定工况片段的窗口尺度。根据前述的分析,窗口尺度的确定不仅影响到模型参数辨识的噪声免疫能力,而且也决定了模型参数辨识的在线运行速度。因此本文采用ADSW来调节数据集的大小以支持TCPSO实现具有噪声免疫能力的在线参数辨识。ADSW的尺度通过电流倍率判据模块和参数辨识结果反馈模块的双模块并行来确定。双模块并行策略的逻辑流程图如图2所示。

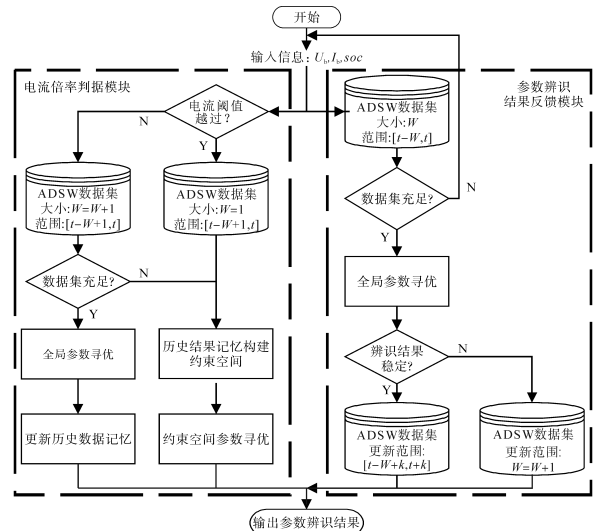


图2 双模块并行策略的逻辑流程图

Fig.2 Logic flow diagram of two-module parallel strategy

左虚线框为电流倍率判据模块,这一模块考虑了电池运行过程中的电流倍率变化对模型参数辨识的影响,以此来提升工况窗口下的模型参数辨识精度。右虚线框为参数辨识结果反馈模块,该模块根据参数辨识结果下的模型预测电压误差来动态放缩窗口尺度。当在线运行时两个模块并行运行并对模型预测电压进行比较,以确定当前参数辨识所需的窗口尺度。

3 噪声干扰下的参数辨识和SOC估计实验验证

3.1 实验数据获取和参考值确定

在实验验证中,模型参数值是未知的。而模型本身和电池运行特性之间存在差异, $SOC-OCV$ 拟合关系随着电池的运行也会发生改变。因此,不同于仿真部分的验证,实验部分的模型存在固有误差,而模型参数在电池充放电过程中也不再是固定值,而是随时间动态改变的参数。因此,实验部分选择真实的电池测试数据来评估噪声干扰下不同参数辨识方法的效果差异。本文采用马里兰大学的电池测试公开数据库作为样本,选择 INR18650-20R 电池在 $25\text{ }^{\circ}\text{C}$ 的动态应力测试(dynamic stress test, DST) 工况作为实验数据^[6]。所采用的数据采样频率均为 1 Hz 。其中 INR18650-20R 的初始容量为 $2\text{ A}\cdot\text{h}$,并将其作为模型的 C_{\max} 。 $SOC-OCV$ 关系通过增量式电流 OCV 测试数据获取,并通过多项式拟合构建多项式函数关系。DST 工况数据如图 3 所示。




图3 实验验证 DST 工况负载数据

Fig.3 Experimental verification of DST load data

由于实验数据在较为理想的环境下进行测试,因此为了验证噪声干扰对模型常辨识和状态估计的影响,将表 2 的高斯白噪声信号附加到测

试数据中。在实验部分,FRSL 的遗忘因子权重仍然设置为 0.999。本文仍然选择 RLS-EKF, FRSL-EKF 和 TCPSO-EKF 三种协同算法进行对比分析,三种方法的 EKF 保持完全一致。

表 2 附加在实验工况上的噪声信号

Tab.2 Noise signal attached to experimental conditions

实验编号	噪声干扰类型	电压噪声方差 σ_v^2/mV^2	电流噪声方差 σ_i^2/mA^2
实验 1	OE	10	0
实验 2	OE	100	0
实验 3	IE	0	100
实验 4	IE	0	0.001
实验 5	EIV	10	100

评估三种方法的噪声干扰免疫能力的前提是确定模型参数和 SOC 的实时真实值。实时真实值将通过安时积分法获取,首先确定已知初始值为 $SOC=80\%$,选择未添加任何噪声的 DST 工况负载电流数据进行下式计算:

$$SOC_k = SOC_{k-1} + \eta i_{b,k} \Delta t / C_{\max} \quad (21)$$

SOC 估计的实时参考值如图 4 所示。




图 4 实验验证 SOC 估计实时参考值

Fig.4 Experimental verification of real-time reference value for SOC estimation

模型参数的真实值采用离线参数辨识方法得到。辨识数据选择未附加任何噪声干扰的原始电压、电流测试数据。本文通过固定窗口尺度下的粒子群算法确定模型的离线参数。DST 工况划分为大电流倍率工况和小电流倍率工况。基于模型的离线参数辨识可以得到对应的模型预测电压。模型预测电压和真实测量电压之间的绝对误差如图 5 所示。从图 5 中可得预测电压的最大绝对误差小于 15 mV 。由此可得,离线参数辨识结果准确可靠,而模型预测电压误差主要来自模型和电池特性之间的误差以及 $SOC-OCV$ 关系的拟合误差。

由此可得模型参数的离线参考值可以近似为模型参数的真实值。而在工况下的离线参考值 R_0, R_p, C_p 和 τ 如图 6 所示。




图5 实验验证离线参数辨识下的模型预测电压绝对误差
Fig.5 Experiments verify the absolute error of model predicted voltage under offline parameter identification

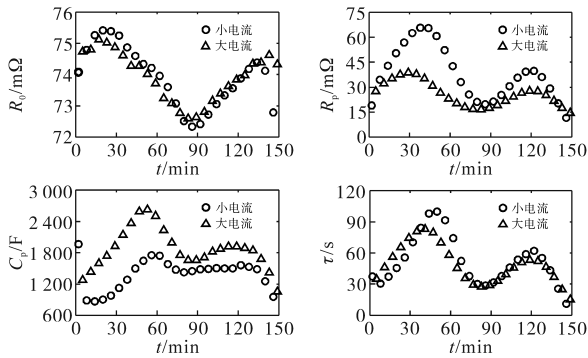


图6 实验验证无噪声条件下的离线参数辨识结果
Fig.6 Experiments to verify the results of offline parameter identification under noise-free conditions

图6中,圆圈表示小电流倍率工况下的离线参考值,三角形表示大电流倍率下的离线参考值。从图中可得参数 R_0 和 τ 在不同的电流倍率工况下的差异较小,说明这两个参数对电流倍率的敏感性较低。而 R_p 和 C_p 在不同的电流倍率下的差异显著。当电池在大电流率工况下运行时,由于温度等因素的影响, R_p 的值将减小。由于时间常数 τ 在不同电流倍率工况下的差异很小,因此当 R_p 减小时 C_p 将增大。如图6所示,模型的参数真实值是时变的。因此也再次说明在线参数辨识以提升SOC估计精度的必要性。

3.2 实验验证和结果分析

本文考虑一阶RC模型的性能和实际工程应用,仅分析SOC(20%~80%)区间的参数辨识和SOC估计性能。图7为在三类噪声问题下的参数辨识结果和SOC估计误差。如表3所示,SOC估计的平均绝对误差(mean absolute error, MAE)和RMSE量化地评估了SOC估计的准确性。

为了分析电压噪声干扰下的参数辨识准确性以及电压噪声增大对模型参数辨识的影响,在OE问题中,分别施加 $\sigma_v^2 = 10 \text{ mV}^2$ 和 $\sigma_v^2 = 100 \text{ mV}^2$ 的电压噪声信号。两种噪声干扰下的实验结果分别如图7a和图7b所示。如表3所示,在电压噪声干扰下TCP SO-EKF的SOC估计RMSE均小于

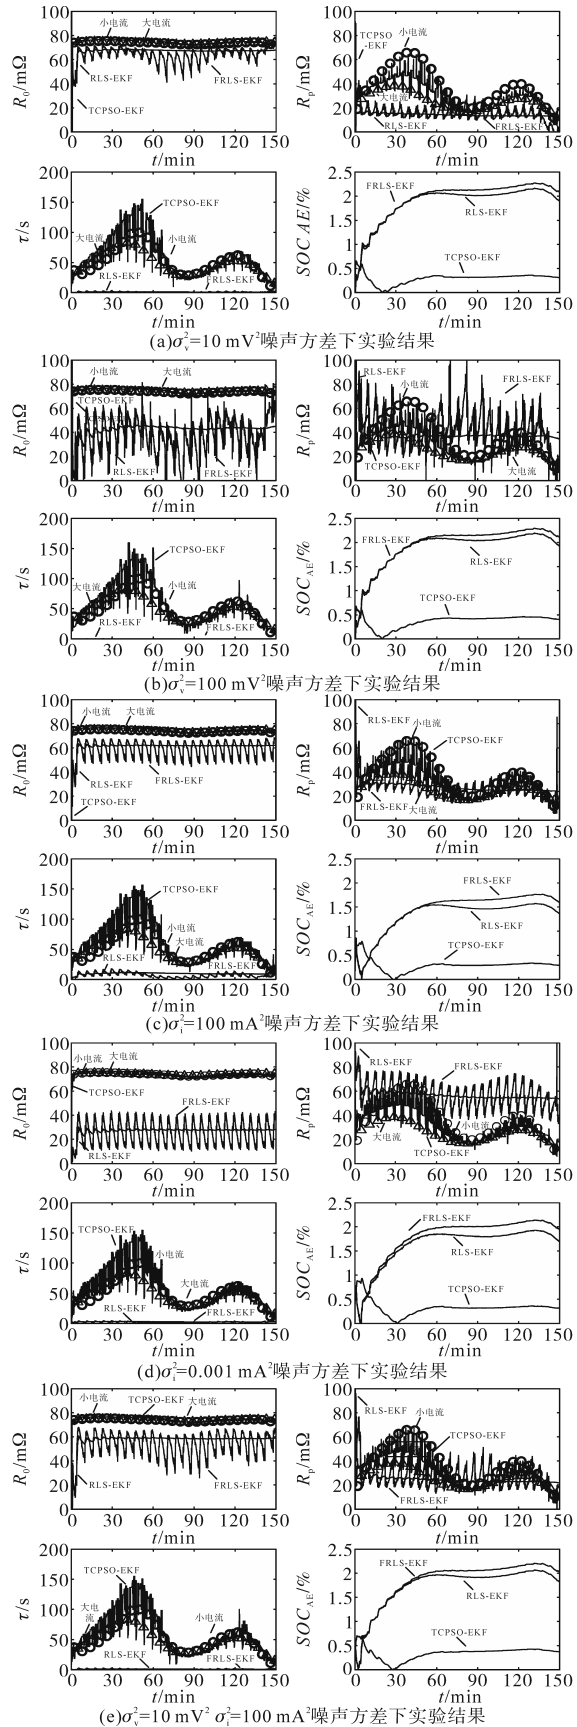


图7 不同噪声干扰下的模型参数辨识和SOC估计实验验证结果
Fig.7 Experimental verification results of model parameter identification and SOC estimation under different noise disturbances

表3 噪声干扰下的SOC估计实验结果
Tab.3 Experimental results of SOC estimation
under noise interference

编号	噪声方差	方法	MAE/%	RMSE/%
实验1	$\sigma_v^2 = 10 \text{ mV}^2$	RLS-EKF	1.944 3	1.958 2
		FRLS-EKF	1.968 8	1.984 4
		TCPSO-EKF	0.316 8	0.340 8
实验2	$\sigma_v^2 = 100 \text{ mV}^2$	RLS-EKF	1.948 2	1.963 3
		FRLS-EKF	1.974 5	1.991 4
		TCPSO-EKF	0.387 3	0.410 6
实验3	$\sigma_i^2 = 100 \text{ mA}^2$	RLS-EKF	1.403 0	1.423 6
		FRLS-EKF	1.458 8	1.483 7
		TCPSO-EKF	0.279 2	0.295 2
实验4	$\sigma_i^2 = 0.001 \text{ mA}^2$	RLS-EKF	1.732 6	1.753 3
		FRLS-EKF	1.782 1	1.805 6
		TCPSO-EKF	0.331 4	0.350 0
实验5	$\sigma_v^2 = 10 \text{ mV}^2$ $\sigma_i^2 = 100 \text{ mA}^2$	RLS-EKF	1.837 0	1.855 5
		FRLS-EKF	1.873 6	1.894 4
		TCPSO-EKF	0.359 5	0.380 9

0.42%,较其他两种方法也至少下降了1.55%,而MAE均小于0.39%,较其他两种方法至少下降了1.56%。与实验1相比,随着电压噪声信号的方差增大,RLS-EKF方法得到的参数辨识结果 R_0 呈现更大的偏置。此外,由图7a和图7b可以发现,当电压噪声增大时,采用FRLS-EKF的参数辨识结果不仅呈现出进一步的偏置,而且参数辨识的波动更大。从表3可得,随着电压噪声方差的增大,三种方法得到的SOC估计的RMSE和MAE均增大。然而,当电压噪声方差增大时,TCPSO-EKF方法仍然比其他两种方法在参数辨识和SOC估计精度方面具有显著优势。

为了分析IE问题下的参数辨识准确性以及电流噪声增大对模型参数辨识的影响,在IE问题中,分别施加 $\sigma_i^2 = 100 \text{ mA}^2$ 和 $\sigma_i^2 = 0.001 \text{ mA}^2$ 的电流噪声。两种噪声干扰下的实验结果分别如图7c和图7d所示。在电流噪声干扰下,如表3所示,TCPSO-EKF的SOC估计RMSE均小于0.39%,而MAE均小于0.34%,较其他两种方法均至少下降了1.12%。对比实验3和实验4可得,RLS-EKF和FRLS-EKF的模型参数辨识结果在电流噪声方差增大时发生了进一步的偏置。从表3中可得,电流噪声方差的增大也使得三种方法SOC估计的RMSE和MAE增大。然而TCPSO-EKF方法仍然具有良好的电流噪声免疫能力。

而对比图7b和图7c的参数辨识结果可知,在相同的噪声方差下,参数辨识对电压噪声更加敏感。

为了验证电压电流噪声同时干扰对模型参数辨识和SOC估计的影响,实验5中在原始信号的基础上附加方差为 $\sigma_v^2 = 10 \text{ mV}^2$ 电压噪声信号和方差为 $\sigma_i^2 = 100 \text{ mA}^2$ 的电流噪声信号。EIV问题下的实验结果如图7e所示。与仿真结果类似,在使用RLS-EKF或FRLS-EKF时,在实验中噪声干扰也会产生模型参数辨识结果的偏置。在实验5中,遗忘因子作用也会引起辨识结果的剧烈波动。由于模型误差和SOC—OCV关系拟合误差的存在,SOC估计误差大于仿真中的SOC估计误差。然而在实验中尽管模型参数实时变化、模型以及SOC—OCV关系也存在固有误差,但是如表3所示,在EIV问题下,TCPSO-EKF的SOC估计RMSE<0.39%,而MAE也均小于0.36%,本文所提方法仍然具有很高的SOC估计精度。

在实验验证中,RLS-EKF和FRLS-EKF的参数辨识结果在噪声干扰下存在较大的偏置,且随着噪声的增大,偏置更加显著。通过实验结果也可以发现 τ 的辨识结果偏置尤为严重,这是由于在恒流过程中对应的电压动态过程是缓慢非突变的,此时的噪声对电压电流信号的平滑过程影响更大。由于递归算法的辨识输入信息仅为 t 和 $t-1$ 时刻的电压、电流信号,因此 τ 的辨识结果受噪声的影响存在较大的向下偏差。TCPSO-EKF方法利用工况片段作为辨识输入信息,通过统计特征分析来探索动态电压过程的总体趋势,有助于获得可靠的参数辨识结果。

图7中的参数辨识结果表明,TCPSO-EKF方法的参数辨识结果收敛于离线参考值附近。但在40—60 min区间 τ 的辨识结果向上偏置,这是由于在这一时间区间中大、小电流倍率下的模型参数 R_p 和 C_p 的参数真实值差异较大。TCPSO-EKF的参数辨识结果是工况片段下的拟合最优结果,当参数变化迅速时,对参数的跟踪性能略显不足。

3.3 计算成本分析

在线参数辨识和EKF协同估计中,计算成本是评价方法适应在线运行的重要因素。为了验证TCPSO-EKF的运行速度,本文将三种方法重复运行10次,取平均CPU时间进行对比分析。上述参数辨识方法和SOC估计方法是在2.9 GHz处理器和16 GB RAM的计算机上通过Matlab

2019b的m文件运行。CPU时间通过Matlab的tic和toc来确定。RLS-EKF, FRLS-EKF, TCPSO-EKF三种方法的平均CPU时间分别为0.011 4, 0.010 5和2.235 3。由此可得, RLS-EKF和FRLS-EKF在运行速度上相较于TCPSO-EKF具有显著优势。但是TCPSO-EKF的平均运行时间仍仅为采样周期的1/450。由于窗口数据集的辨识结果是数据片段的统计特征, TCPSO在ADSW下进行参数辨识时会有轻微的延迟。然而, 上述分析和验证表明, 延迟对参数辨识和SOC估计的影响很小。从图7和三种方法的平均CPU时间可以看出, TCP-SO-EKF方法完全适合于s级的在线模型参数辨识和SOC估计。此外, 尽管TCPSO-EKF牺牲了一定的运行速度, 但在噪声干扰下的模型参数辨识和SOC估计方面具有显著的精度优势。

4 结论

在锂离子电池大规模应用于电网储能和电动汽车等领域的同时, 电池的安全性和可靠性问题也日益突出。而准确可靠的模型参数和SOC估计是确保锂离子电池安全高效可靠运行的关键保障。首先对锂离子电池的基本特性进行了测试和分析, 包括不同OCV测试方法的对比和SOC-OCV关系的拟合。针对噪声干扰问题, 分析了在OE, IE和EIV噪声干扰下RLS等最小二乘原理下的参数辨识偏置问题。在此基础上采用TCPSO算法来实现噪声免疫模型参数辨识, 并结合EKF提高了噪声干扰下的SOC估计准确性。实验证明本文所提方法在噪声干扰下的SOC估计最大误差小于1%。为了验证所提方法的在线运行可行性, 进行了三种方法的计算成本的分析, 验证结果表明, TCPSO-EKF的平均CPU计算时间仅为采样周期的1/450, 因此该方法可以适应于s级在线参数辨识和EKF的协同SOC估计, 且具有较好的模型参数辨识噪声免疫性能。

参考文献

- [1] 顾钟凡, 陈玉伟, 李承澳, 等. 基于DFFRLS和神经网络-ASRUKF算法的蓄电池SOC估计[J]. 电气传动, 2022, 52(17): 59-65, 80.
- [2] 于东民, 杨超, 蒋林洳, 等. 电动汽车充电安全防护研究综述[J]. 中国电机工程学报, 2022, 42(6): 2145-2163.
- [3] 颜湘武, 邓浩然, 郭琪, 等. 基于自适应无迹卡尔曼滤波的动力电池健康状态检测及梯次利用研究[J]. 电工技术学报, 2019, 34(18): 3937-3948.
- [4] 孙道明. 动力锂离子电池SOC和容量估计方法研究[D]. 杭州: 浙江大学, 2021.
- [5] 蔡敏怡, 张娥, 林靖, 等. 串联锂离子电池组均衡拓扑综述[J]. 中国电机工程学报, 2021, 41(15): 5294-5310.
- [6] 张吉昂, 王萍, 程泽. 基于充电电压片段和融合方法的锂离子电池SOC-SOH-RUL联合估计[J]. 电网技术, 2022, 46(3): 1063-1072.
- [7] 李哲, 卢兰光, 欧阳明高. 提高安时积分法估算电池SOC精度的方法比较[J]. 清华大学学报(自然科学版), 2010, 50(8): 1293-1296.
- [8] 程泽, 杨磊, 孙幸勉. 基于自适应平方根无迹卡尔曼滤波算法的锂离子电池SOC和SOH估计[J]. 中国电机工程学报, 2018, 38(8): 2384-2393, 2548.
- [9] 庞辉, 郭龙, 武龙星, 等. 考虑环境温度影响的锂离子电池改进双极化模型及其荷电状态估算[J]. 电工技术学报, 2021, 36(10): 2178-2189.
- [10] 黄凯, 郭永芳, 李志刚. 考虑迟滞效应影响的动力锂离子电池

(下转第64页)