

DOI:10.19322/j.cnki.issn.1006-4710.2022.01.017

基于小波变换的 VFFRLS 锂电池参数辨识

任碧莹, 徐玮浓, 孙 佳, 孙向东

(西安理工大学 电气工程学院, 陕西 西安 710054)

摘要: 锂离子电池管理系统的可靠性通常是建立在高精度的电池模型参数辨识的基础上, 因其在实际运行与测量环境中往往会受到噪声干扰, 使采样信号中存在噪声信号, 从而导致常规辨识算法下的参数辨识精度受到影响。因此, 本文以锂离子电池二阶 RC 模型为研究对象, 分析了遗忘因子更新过程中噪声对常用的可变遗忘因子递推最小二乘法(VFFRLS)的影响, 进而提出一种基于小波变换的 VFFRLS 的参数辨识算法。利用小波变换的多尺度多分辨率特性对采样信号进行分频处理, 再采用 VFFRLS 进行参数辨识, 解决了因噪声影响遗忘因子带来的跟踪性能不佳的问题。实验结果表明, 本文提出的算法具有更高精度的辨识结果。

关键词: 锂离子电池; 参数辨识; 遗忘因子; 噪声干扰

中图分类号: TM912.9

文献标志码: A

文章编号: 1006-4710(2022)01-0133-09

Lithium-ion battery parameter identification based on VFFRLS with wavelet transform

REN Biying, XU Weinong, SUN Jia, SUN Xiangdong

(Faculty of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China)

Abstract: The reliability of Li-ion battery management system is usually based on the high-precision identification of battery model parameters. Because of the noise interference in the actual operation and measurement environment, the noise in the sampling signal is usually caused, which results in the influence of the parameter identification accuracy by the conventional identification algorithm. Therefore, in this paper, the second-order RC model of lithium-ion battery is taken as the research object, with the influence of noise on the common variable forgetting factor recursive least square(VFFRLS) in the process of updating forgetting factors analyzed. A parameter identification algorithm is proposed, which is VFFRLS based on wavelet transform. The multi-scale and multi-resolution characteristics of wavelet transform are used to divide the frequency of the sampling signal, with VFFRLS used to identify the parameters. The problem of poor tracking performance caused by the forgetting factor caused by noise is solved. The experimental results show that the proposed algorithm has higher accuracy identification results.

Key words: lithium-ion battery; parameter identification; forgetting factor; noise interference

电动汽车锂离子电池因其能量密度高、自放电率低、安全可靠等优点被广泛应用^[1]。其应用时需要安全稳定的工作环境, 而对荷电状态(state of charge, SOC)的准确估计是保证其性能充分发挥, 避免过充、过放并延长使用寿命的重要基础^[2]。高精度的 SOC 估计依赖于电池模型参数的准确度, 因此, 提高电池模型参数辨识的精度十分重要。

基于等效电路模型的参数辨识方法中, 以递推最小二乘法(recursive least square, RLS)的应用最为广泛。RLS 计算量小, 简单易实现, 但随着系统获取的数据量的增大, 新数据提供的信息逐渐被旧数据淹没, 使算法失去校正能力, 即出现“数据饱和”现象^[3,4]。为了避免该现象的发生, 要求加大新数据在计算中所占的权重, 因此, 文献[5,6]研究了含

收稿日期: 2021-05-26; 网络出版日期: 2021-08-02

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1294.n.20210802.1056.002.html>

基金项目: 国家自然科学基金资助项目(51577155); 陕西省自然科学基金资助项目(2020JM-449)

第一作者: 任碧莹, 女, 博士, 教授, 硕导, 研究方向为新能源发电技术与微电网控制技术。E-mail: renby@126.com

通信作者: 徐玮浓, 女, 硕士生, 研究方向为电池管理和储能变换器技术。E-mail: 965043218@qq.com

遗忘因子的递推最小二乘法(forgetting factor recursive least square, FFRLS),通过引入遗忘因子,使系统能够更加充分地利用新数据中的信息,降低旧数据对系统的影响,从而使系统参数得到更准确的估计,提高时变系统的辨识精度。为了更进一步提高时变系统的辨识精度,许多学者以 FFRLS 为基础,从算法本身出发,根据其性能对算法进行改进。文献[7]研究了一种 VFFRLS 算法,它是根据预测误差确定遗忘因子,并随算法的进程而自适应地改变。当信号存在剧烈波动的情况或存在数据错误或丢失的情况时,该方法可以有效提高参数识别的收敛速度并减少辨识错误,但该方法高效的收敛能力可能会受到预测误差的影响。文献[8]提出了一种根据模型中各参数自身的物理特性来独立调整遗忘因子的方法,以适应深度放电范围和高动态工作条件下参数的极大变化,然而该方法主要是为了保证锂电池在深度放电情况下对参数的动态跟踪精度。文献[9]指出,模型中各单个参数的变化速率可能存在偏差,单一的遗忘因子难以衡量参数辨识能力与收敛性和稳定性之间的关系,因此在进行参数辨识时,需要对不同参数进行不同速率的校正,故该文献提出了一种基于解耦多遗忘因子的递推最小二乘法,对具有不同变化率的各个参数进行独立跟踪,但该算法的应用需要以简单模型为前提,在更精确更高阶的模型中难以应用。

此外,还有许多学者就外部参数对辨识效果的影响问题对算法展开研究,由于实际应用中存在电磁干扰或传感器分辨率低的情况,电池系统容易受到噪声的意外感应,出现变量误差问题^[10-12]。文献[10]提出了一种偏置补偿递归最小二乘法以克服辨识固有误差,但该方法需要噪声统计信息,而统计信息较难获得。文献[13]提出了一种自适应遗忘递归总最小二乘法,并结合带有增益调度的 Luenberger 观测器来补偿噪声影响,但计算量大。

通过对各文献的分析可知,遗忘因子会影响算法对噪声的敏感度以及收敛性的优劣程度,在进行大量数据分析时,可能存在不易平衡分离噪声与收敛性的问题。因此,本文提出基于小波变换的可变遗忘因子递推最小二乘法(WVFFRLS)来进行电池参数的动态辨识。该算法具有准确性高、收敛性快的辨识效果,通过与 VFFRLS 的实验对比,验证了本文所提出的参数辨识方法的可行性。

1 VFFRLS 参数辨识存在的问题

1.1 锂电池模型

目前,锂电池等效模型主要有内阻模型、阻容模型、PNGV 模型、GNL 模型以及戴维南模型。其中,戴维南模型又称 n 阶 RC 模型,因其能够反映出电池内部参数与外部参数如温度与电流之间的关系,并且能够良好地表征电池的动态特性,故应用更为普遍^[3]。而该模型的精度、计算复杂度与应用难度皆随 RC 阶数的增大而增大。因此,综合考虑计算复杂度及精度,锂电池等效模型通常选取二阶 RC 等效电路模型。锂电池二阶 RC 等效电路模型如图 1 所示,模型中的参数包括电池内阻 R_0 ,极化电阻 R_1, R_2 ,极化电容 C_1, C_2 ,两个并联 RC 分别表示了电池的电化学极化过程与浓差极化过程。 U_{OC} 表示开路电压, U_L 表示端电压。




图 1 锂离子电池二阶 RC 等效电路模型

Fig. 1 Second-order RC equivalent circuit model of a lithium-ion battery

对二阶 RC 等效电路模型的时域关系进行拉普拉斯变换,得到参数与观测值的关系表达式:

$$U_L(s) =$$

$$U_{OC}(s) - \left(R_0 + \frac{1}{sC_1 + \frac{1}{R_1}} + \frac{1}{sC_2 + \frac{1}{R_2}} \right) I(s) \quad (1)$$

令 $U(s) = U_{OC}(s) - U_L(s)$, $\tau_1 = R_1 C_1$, $\tau_2 = R_2 C_2$, $a = \tau_1 \tau_2$, $b = \tau_1 + \tau_2$, $c = R_0 + R_1 + R_2$, $d = R_0(\tau_1 + \tau_2) + R_1 \tau_2 + R_2 \tau_1$, 对式(1)进行离散化处理并整理,得到可用于最小二乘法参数辨识的差分方程:

$$U(k) = k_1 U(k-1) + k_2 U(k-2) + k_3 I(k) + k_4 I(k-1) + k_5 I(k-2) \quad (2)$$

其中, $k_0 = a + bT + T^2$, $k_1 = (2a + bT)/k_0$, $k_2 = -a/k_0$, $k_3 = (aR_0 + dT + cT^2)/k_0$, $k_4 = -(2aR_0 + dT)/k_0$, $k_5 = aR_0/k_0$ 。

式(2)可写为如下形式:

$$Y(k) = \mathbf{X}(k) \hat{\boldsymbol{\theta}}(k) \quad (3)$$

式中: $Y(k) = U(k)$ 为 k 时刻系统观测值; $\mathbf{X}(k) = [U(k-1) U(k-2) I(k) I(k-1) I(k-2)]$ 为系统信息向量; $\hat{\boldsymbol{\theta}}(k) = [k_1 k_2 k_3 k_4 k_5]^T$ 为待估参数向量; T 为采样周期。

通过辨识算法得到待估参数 k_1, k_2, k_3, k_4, k_5 的估计值,进一步反推可得出对应的电池参数 R_0, R_1, R_2, C_1, C_2 的值。

1.2 VFFRLS 中遗忘因子对辨识算法的影响

VFFRLS 算法通过最小化观测值与估计值的误差平方和,并利用遗忘因子分离系统噪声,平衡算法收敛性与系统跟踪能力,最终得到等效电路模型中的最优参数值。该算法的递推过程如式(4)~(7)^[6,14]。其中, $\mathbf{K}(k)$ 为卡尔曼增益, $\mathbf{P}(k)$ 为协方差矩阵, λ 为遗忘因子, $\sigma_e(k)$ 为先验误差信号功率, $\sigma_q(k)$ 为后验误差信号功率, $\sigma_v(k)$ 为系统噪声功率。将 VFFRLS 算法应用于锂离子电池模型的参数辨识过程中,根据式(4)~(7)得到参数向量 $\hat{\boldsymbol{\theta}}(k)$,进一步可得到电池参数值。

$$\mathbf{K}(k) = \frac{\mathbf{P}(k-1)\mathbf{X}(k)}{\mathbf{X}^T(k)\mathbf{P}(k-1)\mathbf{X}(k) + \lambda} \quad (4)$$

$$\hat{\boldsymbol{\theta}}(k) = \hat{\boldsymbol{\theta}}(k-1) + \mathbf{K}(k) [Y(k) - \mathbf{X}^T(k)\hat{\boldsymbol{\theta}}(k-1)] \quad (5)$$

$$\mathbf{P}(k) = \frac{1}{\lambda} [\mathbf{I} - \mathbf{K}(k)\mathbf{X}^T(k)]\mathbf{P}(k-1) \quad (6)$$

$$\lambda(k) = \frac{\sigma_q(k)\sigma_v(k)}{\sigma_e(k) - \sigma_v(k)} \quad (7)$$

式(7)中的各变量表达如式(8)~(12),其中 $e(k)$ 为先验误差, $q(k)$ 为后验误差,公式中的 α 和 β 均为加权因子。

$$\sigma_e(k) = \sqrt{\alpha\sigma_e^2(k-1) + (1-\alpha)e^2(k)} \quad (8)$$

$$e(k) = Y(k) - \mathbf{X}^T(k)\hat{\boldsymbol{\theta}}(k-1) \quad (9)$$

$$\sigma_q(k) = \sqrt{\alpha\sigma_q^2(k-1) + (1-\alpha)q^2(k)} \quad (10)$$

$$q(k) = Y(k) - \mathbf{X}^T(k)\hat{\boldsymbol{\theta}}(k) \quad (11)$$

$$\sigma_v(k) = \sqrt{\beta\sigma_v^2(k-1) + (1-\beta)e^2(k)} \quad (12)$$

根据式(7)可看出,遗忘因子与噪声功率存在一定关系,噪声会通过影响遗忘因子进而对整个算法辨识情况产生影响。

实际系统中通常存在噪声,含噪声的系统模型可表示为:

$$d(k) = y(k) + v(k) = \mathbf{x}(k)\boldsymbol{\theta} + v(k) \quad (13)$$

式中: $d(k)$ 为系统中含有噪声的输出; $y(k) = \mathbf{x}(k)\boldsymbol{\theta}$ 为系统真实值; $v(k)$ 为系统噪声。

要使该模型实现参数的最小二乘法估计,须要求所估值的误差平方和最小,即辨识算法依靠估计误差来驱动,其误差驱动信号为:

$$e(k) = d(k) - \hat{y}(k) = d(k) - \mathbf{x}(k)\hat{\boldsymbol{\theta}}(k-1) \quad (14)$$

其中, $\hat{y}(k) = \mathbf{x}(k)\hat{\boldsymbol{\theta}}(k-1)$ 是根据 $k-1$ 时刻的待估参数 $\hat{\boldsymbol{\theta}}(k-1)$ 计算出的 k 时刻系统的输出。在存在系统噪声 $v(k)$ 的情况下,若误差驱动信号

$e(k)$ 为零,则会在待估参数 $\hat{\boldsymbol{\theta}}(k)$ 中引入噪声,因此,误差驱动的目标应是从混合信号 $y(k) + v(k)$ 中提取噪声信号 $v(k)$ 。

在如式(13)所示的系统模型中使用 VFFRLS

算法时, $\mathbf{X}(k) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)\mathbf{x}^T(i)$, $Y(k) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)d(i)$ ^[14],将 $\mathbf{X}(k)$ 代入式(3)可得:

$$Y(k) = \mathbf{X}(k)\hat{\boldsymbol{\theta}}(k) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)\mathbf{x}^T(i)\hat{\boldsymbol{\theta}}(k) \quad (15)$$

再将 $Y(k)$ 结合式(13)可得:

$$Y(k) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)d(i) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)y(i) + \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)v(i) \quad (16)$$

根据式(15)和式(16)可知:

$$Y(k) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)\mathbf{x}^T(i)\hat{\boldsymbol{\theta}}(k) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)y(i) + \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)v(i) \quad (17)$$

当 λ 非常接近 1 且 k 足够大时,可以认为公式(17)中噪声信息的数学期望为 0,如式(18):

$$\frac{1}{k} \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)v(i) \cong E\{\mathbf{x}(k)v(k)\} = 0 \quad (18)$$

因此,式(17)可写作:

$$Y(k) = \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)\mathbf{x}^T(i)\hat{\boldsymbol{\theta}}(k) \cong \sum_{i=1}^k \lambda^{k-i} \mathbf{x}(i)y(i) \quad (19)$$

此时,系统参数估计值即为参数实际值。又根据式(14)可知,误差信号即为系统噪声:

$$e(k) \cong v(k) \quad (20)$$

当 λ 较小时, $\lambda^n \ll 1$, 则有:

$$\sum_{i=1}^k \lambda^{k-i} \{\cdot\} \cong \sum_{i=k-k_0+1}^k \lambda^{k-i} \{\cdot\} \quad (21)$$

此时,结合式(14)和式(17)可得:

$$e(k) = 0 \quad (22)$$

由此可知,当 λ 较小时,算法收敛性较好,但系统输出估计值为 $\hat{y}(k) \cong y(k) + v(k)$,存在 $v(k)$ “泄露”情况;而当 λ 越接近于 1,系统估计值 $\hat{y}(k)$ 也越接近于 $y(k)$,但收敛性也会逐渐降低。因此,为了更快速地分离噪声并尽可能避免因 λ 过小而导致的系统跟踪能力降低,提出在 VFFRLS 算法基础上引入小波变换来更新遗忘因子,从而提高

算法整体的收敛性与系统的跟踪能力。

2 基于小波变换的 VFFRLS 算法

2.1 小波变换

小波是一种具有能量的微小波动,其能量集中于某一时间及频率上,它是对瞬时、不平稳或时变信号进行分析的有效工具。将任意信号或函数 $f(t)$ 的二进制离散小波变换定义为:

$$W_{2^m} f(n) = \langle f(t), \psi_{2^m}(n) \rangle = \frac{1}{\sqrt{2^m}} \int_{\mathbb{R}} f(t) \bar{\psi}\left(\frac{t}{2^m} - k\right) dt \quad (23)$$

其逆变换为:

$$f(t) = \sum_{m \in \mathbb{Z}} \int_{\mathbb{Z}} W_{2^m} f(n) \psi_{2^m}\left(\frac{t}{2^m} - n\right) dn \quad (24)$$

式中: $\Psi(t)$ 为母小波; 2^m 表示伸缩尺度参数; n 表示平移时间参数。

以 m, n 为基础对信号进行多分辨分析。利用低通滤波器和高通滤波器分别对所给信号进行滤波,将该信号分解为低频信号和低频信号两个部分。不同分解层上的信号 $f(t)$ 的缩放尺度和小波系数为^[15]:

$$\begin{cases} c_{j,k} = \sum_{m \in \mathbb{Z}} h(n-2k) c_{j-1,m} \\ d_{j,k} = \sum_{m \in \mathbb{Z}} g(n-2k) c_{j-1,m} \end{cases} \quad (25)$$

式中: $c_{j,k}$ 为低通滤波器输出后所重构原始信号的近似信号; h 为低通滤波器的系数; $d_{j,k}$ 为高通滤波器输出后所重构原始信号的细节信号; g 为高通滤波器的系数。可由各级信号重构出上级小波公式:

$$A_{j-1,k} = \sum_{n \in \mathbb{Z}} h(k-2n) A_{j,n} + \sum_{n \in \mathbb{Z}} g(k-2n) D_{j,n} \quad (26)$$

2.2 基于小波变换的 VFFRLS 算法

该方法首先对观测向量进行小波分解重构,将所得的低频近似信号作为 VFFRLS 算法中的估计参考值,以所得的高频细节信号作为系统噪声功率,再以该噪声功率为准去更新 λ 。此时,对于作为估计参考值的低频信号,稳态时的信息向量已经更为精确, λ 的作用可近似认为仅提高系统跟踪能力;而对于用以更新 λ 的高频信号,小波变换所得的噪声信息更为精确,在系统存在波动时,能够更好地提高算法的收敛性。

不同的小波基在处理不同信号时各有特点,一般来讲, Daubechies (Db) 小波族因其良好的正交性和紧支撑性,经常被应用于信号处理。对测得的电压信号进行 j 层小波分解重构,分别得到作为估计参考值的低频近似信号 A_j 和作为系统噪声功率的高频细节信号 D_j (j 为层数),其 j 级重构原理如图 2

所示,其中 C_0 为分解重构后的电压信号。本文选取 Db4 小波基进行分解和重构。




图 2 重构过程示意图

Fig. 2 Reconfiguration diagram

根据上述思想,基于小波变换的 VFFRLS 算法应用于锂电池参数辨识时,其具体步骤为:

步骤 1: 对观测向量电压电流进行小波分频,并重构观测向量的低频信号和高频信号;

步骤 2: 因初始化参数选取不当会使系统参数辨识收敛性不佳,甚至不收敛,所以本文通过采用最小二乘法,对大于辨识参数个数的多组参数进行成批处理来优化初始化参数,得到初始化的待估参数 $\theta(0)$ 、协方差矩阵 $P(0)$ 及遗忘因子 $\lambda(0)$;

步骤 3: 将所得观测向量的低频信号作为 VF-FRLS 算法中的信息向量 $X(k)$ 。

步骤 4: 根据式(4)、(5)计算 $K(k)$ 和 $\hat{\theta}(k)$ 。

步骤 5: 根据步骤 4 所得的 $\hat{\theta}(k)$ 及其与电池模型参数的关系(见式(2)),计算出电池模型参数。

步骤 6: 根据式(6)更新协方差矩阵 $P(k)$ 。

步骤 7: 由式(8)~(12)计算噪声功率 $\sigma_e(k)$ 和 $\sigma_q(k)$ 。

步骤 8: 将步骤 1 所得的高频信号作为系统噪声功率 $\sigma_v(k)$ 代入式(7),用以更新遗忘因子 $\lambda(k)$ 。

步骤 9: 循环至数据处理完毕。

算法的具体流程如图 3 所示。

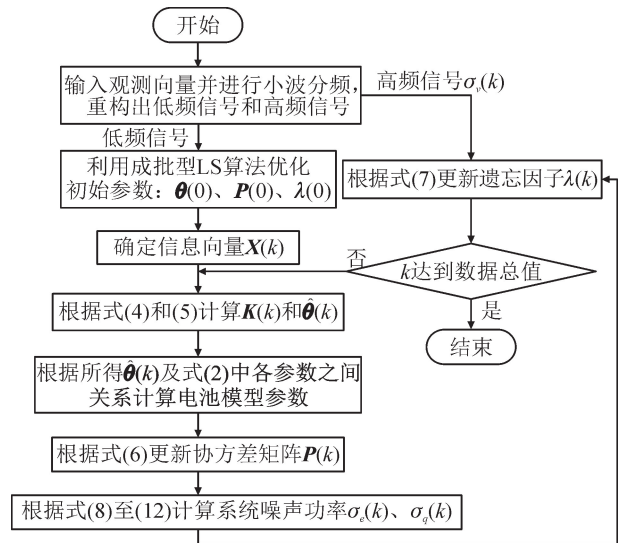


图 3 基于小波变换的 VFFRLS 算法流程图

Fig. 3 Flow chart of VFFRLS algorithm based on wavelet transform

3 实验验证

在参数辨识前,首先进行 U_{oc} 与 SOC 之间的曲线拟合以及递推初始值的优化,在此基础上,再进行参数辨识算法的验证、比较和分析。本文采用山东威能公司生产的磷酸铁锂电池对算法进行验证,该电池参数如表 1 所示。测试平台如图 4 所示,由被测锂离子电池、专用电池测量设备、数据线和带有专用测试软件的计算机组成。

表 1 锂电池参数

Tab. 1 Lithium-ion battery parameters

参数	参数值
额定电压/V	3.2
额定容量/Ah	36.0
充放电截止电流/A	12.0
充电截止电压/V	3.7
放电截止电压/V	2.5

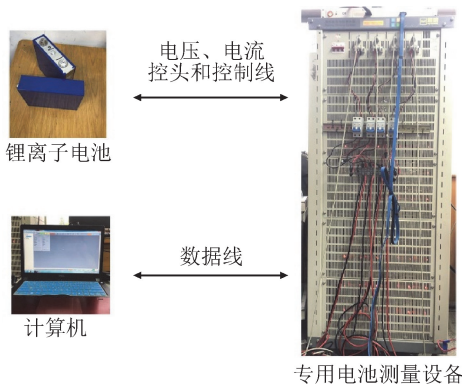


图 4 电池测试平台

Fig. 4 Battery testing platform

采用 0.33C 标准速率电流对锂电池进行间歇恒流充放电实验,对实验数据进行拟合,分别得到充放电时的拟合曲线,如图 5 所示。




图 5 U_{oc} -SOC 关系曲线

Fig. 5 Relationship curves of U_{oc} and SOC

由图 5 可看出,整个充放电过程存在“迟滞现

象”^[16],故取充放电曲线的中间曲线作为开路电压 U_{oc} 与 SOC(以参数 S_{oc} 表示)的关系曲线:

$$U_{oc} = -302.7S_{oc}^8 + 1333S_{oc}^7 - 2432S_{oc}^6 + 2377S_{oc}^5 - 1348S_{oc}^4 + 499.3S_{oc}^3 - 85.82S_{oc}^2 + 8.878S_{oc} + 2.86 \quad (27)$$

3.1 递推初始值的对比和选取

利用成批型的最小二乘法,对大于所需辨识参数个数的 N 组数据,求取参数估计值 $\theta(0)$ 和协方差阵 $P(0)$,并将所得结果作为递推算法的初始值。

以恒流放电工况下应用 VFFRLS 算法的参数辨识结果为基础,分析递推初始值对辨识结果的影响,如图 6 所示。根据仿真结果可看出,随着 N 的增大,收敛性增强,但同时会引起计算量加大及耗时增长,因此,综合考虑后,最终选取 $N=20$ 时的参数估计值和协方差阵作为辨识算法的递推初始值。




图 6 不同初始值对辨识结果的影响

Fig. 6 Influence of different initial values on identification results

3.2 锂电池模型参数辨识

将 WVFFRLS 算法置于动态应力测试(dynamic stress test,DST)和间歇恒流放电工况下进行验证,并与 VFFRLS 算法进行对比分析,其电压电流波形如图 7 所示。图 8 为经小波变换分离出的观测量高频噪声信号。图 9 和图 10 分别显示了两种算法在 DST 工况和间歇恒流放电工况时锂电池参数辨识的结果。图 11 显示了两工况下遗忘因子 λ 的变化曲线。

通过对比可看出,相较于 VFFRLS 算法,WVFFRLS 算法具有更好的收敛性与鲁棒性,并且能够同时反映出各参数随充放电电流变化的动态特性,对电流状态具有良好的识别能力。此外,VF-FRLS 算法中,遗忘因子需要不断平衡算法跟踪能力与噪声敏感度,因此存在较多尖峰,而在 WVFFRLS 算法中,有小波辅助遗忘因子分离噪声,消除了噪声对遗忘因子的干扰,因此遗忘因子尖峰较少。




图 7 DST 工况的电压电流曲线
Fig. 7 Voltage and current curves under the condition of DST




图 8 小波变换所得的各层高频信号
Fig. 8 High frequency signals of each layer obtained by wavelet transform

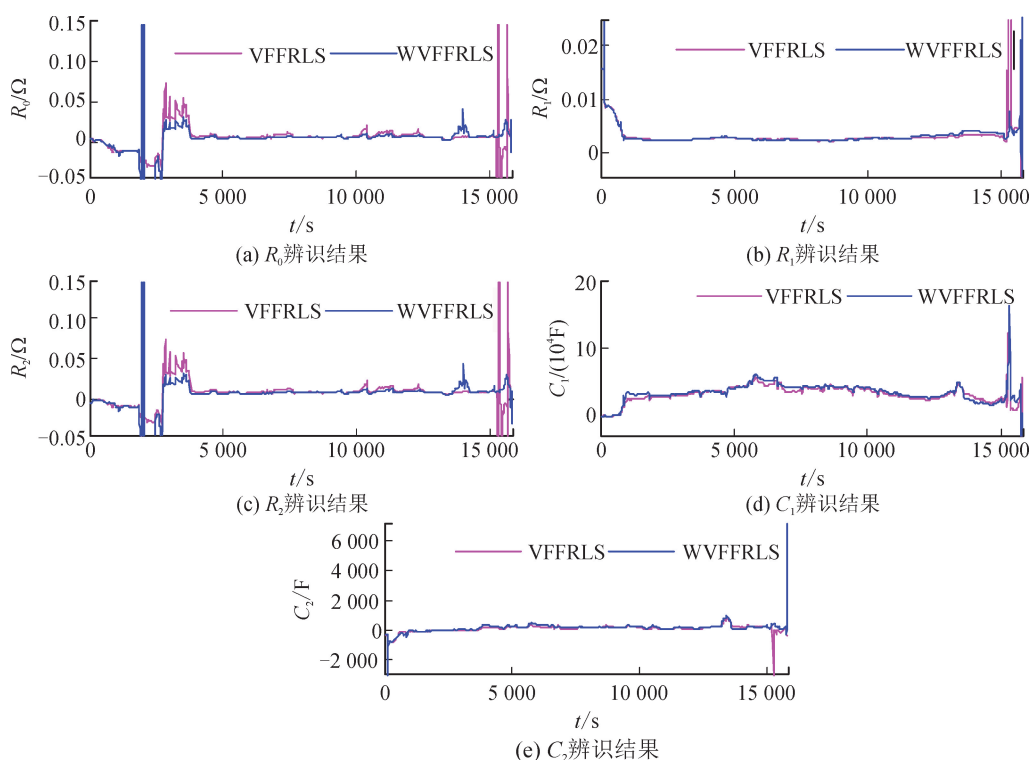


图 9 DST 工况下参数辨识结果
Fig. 9 Parameter identification results under DST condition

3.3 辨识结果分析

图 12 和图 13 分别给出了 DST 和间歇恒流放电工况下,以两种算法辨识结果为依据得到的锂电池模型端电压与真实端电压的对比结果。

由图 12 和图 13 可以看出,两种算法的辨识误差大多都在 $\pm 2\%$ 以内,但 WVFFRLS 算法辨识结果的系统跟踪能力更好。

为了对 VFFRLS 与 WVFFRLS 算法进行综合评价,对两种算法下的参数辨识结果进行误差分析。误差分析主要通过比较端电压估计值与实际值之间的平

均相对误差(mean square error, MRE)和均方根误差(root mean square error, RMSE)来实现^[16]。根据式(28)可以得到两种算法下的辨识误差情况。

$$\begin{cases} R_{\text{MRE}} = \frac{1}{N} \sum_{k=1}^N \frac{|U_{\text{L,a}}(k) - U_{\text{L,e}}(k)|}{U_{\text{L,a}}(k)} \\ R_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{k=1}^N (U_{\text{L,a}}(k) - U_{\text{L,e}}(k))^2} \end{cases} \quad (28)$$

式中: $U_{\text{L,a}}$ 为实际值; $U_{\text{L,e}}$ 为估计值。

将本文结果与各文献所述的其他算法的辨识结果进行对比,对比情况如表 2 所示。




图 10 间歇恒流放电工况下参数辨识结果

Fig. 10 Parameter identification results under intermittent constant current discharge

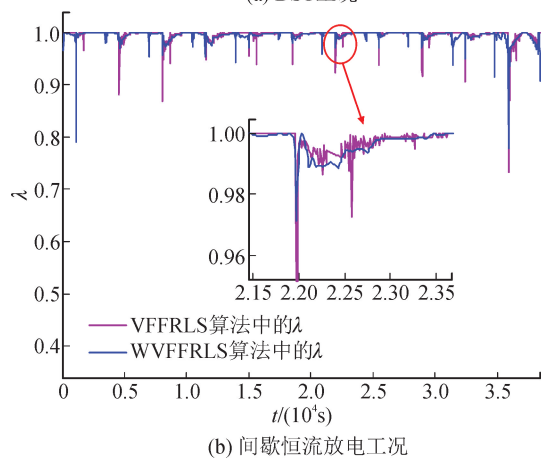

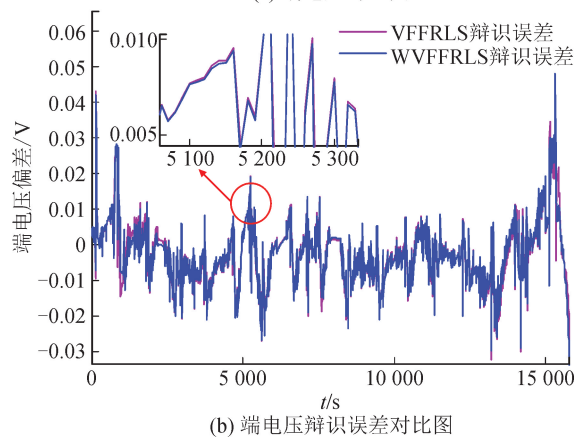

图 11 λ 的变化曲线Fig. 11 Change curve of λ 

图 12 DST 工况下参数辨识结果对比

Fig. 12 Comparison of parameter identification results under DST condition

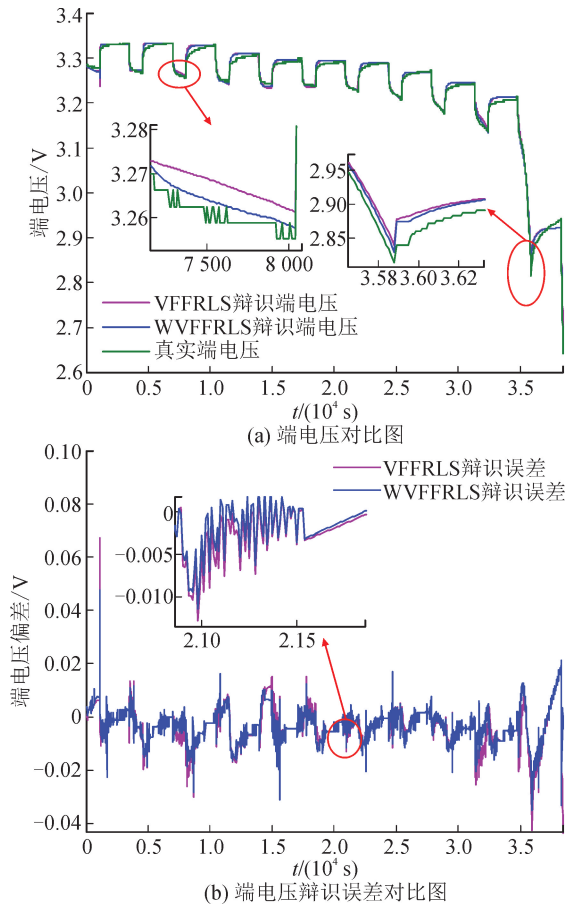


图 13 间歇恒流放电工况下参数辨识结果对比
Fig. 13 Comparison of parameter identification results under intermittent constant current discharge

表 2 不同算法误差情况对比

Tab. 2 Comparison of errors by different algorithms

算法	DST		间歇恒流放电	
	$R_{MRE}/\%$	R_{RMSE}/V	$R_{MRE}/\%$	R_{RMSE}/V
文献[7]算法		0.029 4		
文献[13]算法	0.720 0	0.009 3		
文献[17]算法		0.016 8		
VFFRLS	0.253 7	0.015 9	0.184 08	0.008 22
WVFFRLS	0.231 0	0.010 8	0.161 16	0.006 57

从表 2 可以看出,相较于 VFFRLS 算法, WVFFRLS 算法的辨识结果精度更高。与文献[7]和文献[17]的算法相比,本文所提算法均体现了更好的辨识效果。与文献[13]的算法相比, WVFFRLS 算法的 R_{MRE} 有所下降, R_{RMSE} 相差不大,整体来讲性能更好。再结合图 12 和图 13 可以看出,不管系统处于剧烈波动状态还是相对平稳状态, WVFFRLS 算法的辨识结果都更接近于真实值,算法整体表现出更好的收敛性与系统跟踪能力。

4 结 语

本文以二阶 RC 电路模型作为锂电池的等效模型,分析了遗忘因子在算法中的作用以及对辨识结果的影响,并针对其平衡噪声分离能力与收敛程度的问题提出了基于小波变换的可变遗忘因子递推最小二乘法。在 DST 工况和间歇恒流放电工况下对该算法进行验证,并与 VFFRLS 算法辨识结果进行对比分析。实验结果表明,相较于 VFFRLS 算法, WVFFRLS 算法的辨识结果精度更高,能够实现更好的收敛性以及跟踪性。

参考文献:

- [1] 孙冬,陈息坤. 基于离散滑模观测器的锂电池荷电状态估计[J]. 中国电机工程学报, 2015, 35(1): 185-191.
SUN Dong, CHEN Xikun. Charge state estimation of Li-ion batteries based on discrete-time sliding mode observers[J]. Proceedings of the CSEE, 2015, 35(1): 185-191.
- [2] SUN Xiangdong, JI Jingrun, REN Biying. Adaptive forgetting factor recursive least square algorithm for on-line identification of equivalent circuit model parameters of a lithium-ion battery[J]. Energies, 2019, 12(12): 1-15.
- [3] 陈息坤,孙冬. 锂离子电池建模及其参数辨识方法研究[J]. 中国电机工程学报, 2016, 36(22): 6254-6261.
CHEN Xikun, SUN Dong. Research on lithium-ion battery modeling and model parameter identification methods[J]. Proceedings of the CSEE, 2016, 36(22): 6254-6261.
- [4] REN Biying, XIE Xue, SUN Xiangdong, et al. Parameters identification of lithium-ion battery based on the improved forgetting factor recursive least squares algorithm[J]. IET Power Electronics, 2020, 13(12): 2531-2537.
- [5] ZHOU D, ZHANG K, RAVEY A, et al. Online estimation of lithium polymer batteries state-of-charge using particle filter-based data fusion with multimodels approach[J]. IEEE Transactions on Industry Applications, 2016, 52(3): 2582-2595.
- [6] LI R, WANG Z, YU J, et al. Dynamic parameter identification of mathematical model of lithium-ion battery based on least square method[C]//IEEE International Power Electronics and Application Conference and Exposition (PEAC), 2018.
- [7] SONG Q, MI Y, LAI W. A novel variable forgetting factor recursive least square algorithm to improve the anti-interference ability of battery model parameters identification[J]. IEEE Access, 2019, 7: 61548-61557.

- [8] LIU S, WANG J, LIU Q, et al. Deep-discharging Li-ion battery state of charge estimation using a partial adaptive forgetting factors least square method [J]. IEEE Access, 2019, 7: 47339-47352.
- [9] LIU X, JIN Y, ZENG S, et al. Online identification of power battery parameters for electric vehicles using a decoupling multiple forgetting factors recursive least squares method[J]. CSEE Journal of Power and Energy Systems, 2020, 6(3): 735-742.
- [10] SITTERLY M, WANG L Y, YIN G G, et al. Enhanced identification of battery models for real-time battery management[J]. IEEE Transactions on Sustainable Energy, 2011, 2(3): 300-308.
- [11] LIU L, WANG L Y, CHEN Z, et al. Integrated system identification and state-of-charge estimation of battery systems[J]. IEEE Transactions on Energy Conversion, 2013, 28(1): 12-23.
- [12] WADI A, ABDEL-HAFEZ M F, HUSSEIN A A. Mitigating the effect of noise uncertainty on the online state-of-charge estimation of Li-ion battery cells[J]. IEEE Transactions on Vehicular Technology, 2019, 68(9): 8593-8600.
- [13] WEI Z, ZHAO J, RUI X, et al. Online estimation of power capacity with noise effect attenuation for lithium-ion battery[J]. IEEE Transactions on Industrial Electronics, 2019, 66(7): 5724-5735.
- [14] PALEOLOGU C, BENESTY J, CIOCHINA S. A robust variable forgetting factor recursive least-squares algorithm for system identification[J]. IEEE Signal Processing Letters, 2008, 15: 597-600.
- [15] 肖湘宁. 电能质量分析与控制[M]. 北京: 中国电力出版社, 2010.
- [16] LIN Cheng, YU Quanqing, XIONG Rui, et al. A study on the impact of open circuit voltage tests on state of charge estimation for lithium-ion batteries[J]. Applied Energy, 2017, 205: 892-902.
- [17] HU X, LI S E, YANG Y. Advanced machine learning approach for lithium-ion battery state estimation in electric vehicles[J]. IEEE Transactions on Transportation Electrification, 2016, 2(2): 140-149.

(责任编辑 周 蓓)