DOI：10.13234/j.issn.2095-2805.2025.7.283 **中图分类号**：TM912 **文献标志码**：A

基于改进鲸鱼算法的锂电池模型参数辨识

赵家城，孙 坚，徐红伟
(中国计量大学机电工程学院，杭州 310018)

摘要：锂电池模型参数辨识准确性对开发电池管理系统具有重要意义。为提高参数辨识的准确性和辨识效率，采用对立学习策略和Levy变异改进鲸鱼算法，并结合阿伦尼乌斯定律提出锂电池电化学-热耦合模型多步参数辨识方法。该方法以15、25、35 ℃下的恒流数据进行参数辨识，并通过恒流工况和动态工况验证辨识结果。仿真和实验验证显示，参数平均绝对误差百分比降低了7.2%，模型预测的电压最大均方根误差为26 mV，温度最大均方根误差为0.4 ℃，表明基于改进鲸鱼算法的多步参数辨识方法能够有效辨识参数。

关键词：锂电池；电化学-热耦合模型；参数辨识；鲸鱼算法

Parameter Identification of Lithium Battery Model Based on Improved Whale Optimization Algorithm

ZHAO Jiacheng, SUN Jian, XU Hongwei
(College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou 310018, China)

Abstract: The parameter identification accuracy of a lithium battery model is of significance for the development of a battery management system. To improve the accuracy and efficiency of parameter identification, a multi-step parameter identification method for the electrochemical-thermal coupling model of lithium battery is proposed in combination with the Arrhenius law, which uses the whale optimization algorithm improved by oppositional learning strategy and Levy mutation. In this method, constant-current data at 15 ℃, 25 ℃ and 35 ℃ are adopted for parameter identification, and constant-current and dynamic working conditions are used to verify the identification results. Simulation and experimental results show that the mean absolute percentage error of parameters is reduced by 7.2%, the maximum root mean square error of voltage predicted by the model is 26 mV and that of temperature is 0.4 ℃, indicating that the multi-step parameter identification method using the whale optimization algorithm based on oppositional learning strategy and Levy mutation can efficiently identify parameters.

Keywords: Lithium battery; electrochemical-thermal coupling model; parameter identification; whale optimization algorithm

锂离子电池由于具有高能量密度、低自放电、长寿命和安全可靠等优点，成为新能源汽车领域的核心储能部件，其精确建模和参数识别对准确预测电池状态、实时进行电池监控和提高电池管理具有重要意义。与大多数电池管理系统BMS(battery management system)中使用的等效电路模型ECM(equivalent circuit model)相比，电化学模型EM(electrochemical model)在考虑外推能力和电池内部状态的物理表示方面有许多改进。目前基于EM的BMS研究如状态估计[1]、老化识别[2]、功率预测[3]和快速充电控制[4]，已有较大进展，但高度非线性的模型以及复杂的结构使快速的EM参数识别准确性不高，实际应用效果不理想。传统侵入性参数识别[5-6]耗时长、成本高昂，在某些动态应用中缺乏准确性，因此数据驱动的非侵入性方法因节省

收稿日期：2022-10-17；**修回日期**：2023-01-10，2023-02-06，2023-02-21；**录用日期**：2023-03-07；**网络首发日期**：2023-05-17
基金项目：浙江省科技计划资助项目(2022C01024)
This work is supported by Zhejiang Provincial Science and Technology Plan Project under the grant 2022C01024

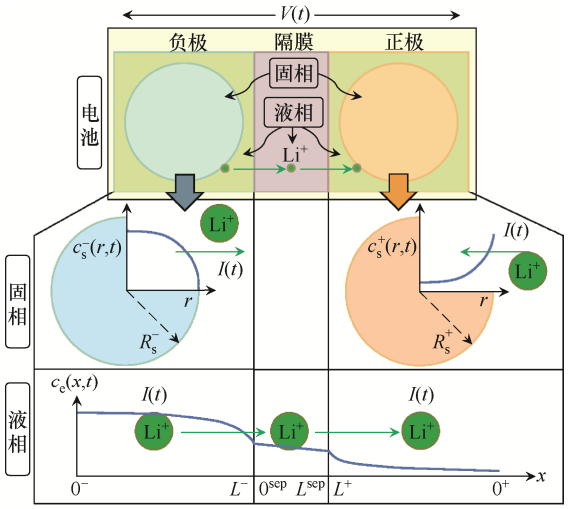
成本和时间而受到关注。

非侵入式方法一般采用非线性最小二乘算法[7-8]、遗传算法 GA(genetic algorithm)[9-10]、粒子群优化 PSO(particle swarm optimization)[11]等算法。文献[7]使用 Levenberg-Marquardt 方法确定降阶 EM 的 9 个参数。然而，Levenberg-Marquardt 方法需要对每个待估参数求偏导，由此造成对 EM 的要求很高，往往需要对复杂模型进行降阶处理以符合使用条件。文献[8]通过构造适用于锂电池模型参数辨识的 3 次样条插值函数，结合最小二乘法辨识模型参数，但采用的 ECM 精度有限，不能很好地体现锂电池在充放电工况变化时的过渡过程。文献[9]采用 GA 识别扩展单粒子模型 SPM(single particle model)的 16 个参数，并针对 2 A·h NMC/石墨电池进行验证，虽然这项工作对 EM 进行了一定程度的改进，但是并未引入传热和能量平衡方程，即并未引入热模型。文献[11]采用 PSO 算法提出 1 种基于大量实验数据集的两步参数识别方法，识别 NMC/石墨电池的 26 个参数。在参数辨识过程中，GA 和 PSO 等元启发式算法因具有易于实现、不需要梯度信息和适用范围广等优点而被广泛应用于 EM 参数辨识。随着元启发式算法的迅速发展，一些性能更为优异的算法开始产生，同时考虑行业需求，在算法和方法层面上现有参数辨识的辨识效率和准确度都需要进一步提高，而且现有的参数辨识大多集中于 EM，并未扩展到电化学-热耦合模型。

针对上述问题，本文提出基于改进鲸鱼算法的锂电池电化学-热耦合模型多步参数辨识方法。首先引入鲸鱼算法 WOA(whale optimization algorithm)，采用对立学习策略和 Levy 变异进行改进；然后结合模型耦合特点提出多步参数辨识方法；最后通过仿真和电池实验验证辨识结果，表明方法的有效性和优势。

1 电化学-热耦合模型

锂电池电化学-热耦合模型由 EM 和热模型组成，模型示意如图 1 所示。



(a) 电化学模型示意

(b) 热模型示意

图 1 模型示意

Fig. 1 Schematic of model

EM 是在伪二维 P2D(pseudo- two-dimensional)电化学模型[12]基础上引入一系列假设推导得出的包含电解质动力学的单粒子模型 SPME(single particle model with electrolyte dyna-mics)[13]，EM 示意如图 1(a)所示。在假设纵向均匀的情况下，热模型采用基于热电相似原理的双态模型来描述圆柱形电池的径向热动力学[14-15]，热模型示意如图 1(b)所示。热模型温度影响扩散系数、反应速率常数等电化学参数，进而影响到电化学模型的电压输出。参数的变化规律满足阿伦尼乌斯定律[16]，即

$$X_i = X_{i,\mathrm{ref}} \exp\left[\frac{\bar{E}_l}{R}\left(\frac{1}{T_{\mathrm{ref}}}-\frac{1}{T}\right)\right] \tag{1}$$

式中：X_i 为电化学参数；$X_{i,\mathrm{ref}}$ 为参考温度 T_{ref} 下的参数；$\bar{E}_l$ 为参数 X_i 对应的活化能；R 为通用气体常数。SPME 模型参数变化又影响产热率，从而影响到热模型输出的温度。通过将温度关联参数和热效应之间的关系反馈到模型中，建立 1 种电化学-

热耦合模型 SPMET (single particle model with electro- lyte and thermal dynamics)，该模型框图如图 2 所示。

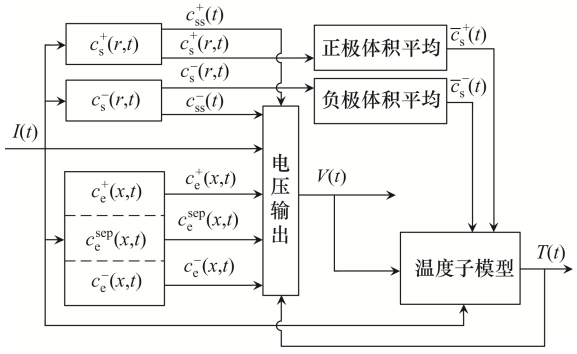


图 2　SPMET 模型框图

Fig. 2 Block diagram of SPMET model

锂电池电化学–热耦合模型的控制方程及边界条件见表 1。表 1 中：γ 为粒子半径方向上的距离，m；t 为时间，s；x 为电负极、隔膜、正极方向上的距离，m；$L^{\pm,\mathrm{sep}}$ 为电池负相隔膜、正极的长度 m；$c_{\mathrm{s}}^{\pm}$、$c_{\mathrm{e}}^{+,-,\mathrm{sep}}$ 分别为固、液相锂浓度，mol/m^3；$\phi_{\mathrm{s}}^{\pm}$、$\phi_{\mathrm{e}}^{\pm}$ 分别为固、液相电势，V；$i_{\mathrm{e}}^{\pm}$ 为离子电流，A/m^2；$i_0^{\pm}$ 为交换电流密度，A/m^2；I 为激励电流，A/m^2；$D_{\mathrm{s}}^{\pm}$、D_{e} 分别为固、液相扩散系数，m^2/s；$\kappa^{+,-,\mathrm{sep}}$ 为电解液电导率，1/(Ω·m)；$a^{\pm}$ 为比界面表面积，m^2/m^3；$U^{\pm}$ 为固相开路电位，V；$R_{\mathrm{s}}^{\pm}$ 为固相粒子半径，m；R_{u} 为外部热阻，K/W；$j_{\mathrm{n}}^{\pm}$ 为摩尔离子通量，mol/(m^2·s)；$\eta^{\pm}$ 为过电位，V；V 为终端电压，V；t_{c}^0 为转移数；R 为理想气体常数，J/(mol·K)；α_{a}、α_{c} 为电荷转移系数；$R_{\mathrm{f}}^{\pm}$ 为固液界面膜电阻，Ω·m^2；C_{c} 为内部热容，J/K；R_{c} 为内部热阻，K/W；$c_{\mathrm{ss}}^{\pm}$ 为固体颗粒表面锂浓度，mol/m^3；$\theta^{\pm}=c_{\mathrm{ss}}^{\pm}/c_{\mathrm{s,max}}^{\pm}$ 为归一化表面浓度；$\varepsilon_{\mathrm{s}}^{\pm}$、$\varepsilon_{\mathrm{e}}^{+,-,\mathrm{sep}}$ 分别为固、液相体积分数；F 为法拉第常数，C/mol；$k^{\pm}$ 为反应速率常数，m$^{2.5}$/(mol$^{0.5}$·s)；$c_{\mathrm{s,max}}^{\pm}$ 为固相最大锂浓度，mol/m^3；T_{s} 为电池表面温度，k；T_{c} 为电池核心温度，k；T_{amp} 为外界环境温度，k；C_{s} 为表面热容，J/K；E_{ocv} 为电池开路电压，V。

对上述模型进行参数辨识。在众多可用于参数辨识的元启发式算法中，鲸鱼算法因具有参数设置较少、收敛速度较快、原理简单和易于实现等优点而受到关注。

表 1　SPMET 模型的控制方程和边界条件

Tab. 1 Control equations and boundary conditions for SPMET model

机制	方程及边界条件
固相扩散	$\dfrac{\partial c_{\mathrm{s}}^{\pm}}{\partial t}(r,t)=\dfrac{1}{r^2}\dfrac{\partial}{\partial r}\left[D_{\mathrm{s}}^{\pm}r^2\dfrac{\partial c_{\mathrm{s}}^{\pm}}{\partial t}(r,t)\right]$
	$\left.\dfrac{\partial c_{\mathrm{s}}^{\pm}}{\partial r}\right\vert_{r=0}=0,\left.\dfrac{\partial c_{\mathrm{s}}^{\pm}}{\partial r}\right\vert_{r=R_{\mathrm{s}}^{\pm}}=\mp\dfrac{1}{D_{\mathrm{s}}^{\pm}Fa^{\pm}L^{\pm}}$
	$\dfrac{\partial c_{\mathrm{e}}^{\pm}}{\partial t}(x,t)=\dfrac{\partial}{\partial x}\left[D_{\mathrm{e}}\dfrac{\partial c_{\mathrm{e}}^{\pm}}{\partial x}(x,t)\right]\pm\dfrac{1-t_{\mathrm{c}}^0}{\varepsilon_{\mathrm{e}}^{\pm}FL^{\pm}}I(t)$
液相扩散	$\left.\dfrac{\partial c_{\mathrm{e}}}{\partial x}\right\vert_{x=0^-}=\left.\dfrac{\partial c_{\mathrm{e}}}{\partial x}\right\vert_{x=0^+}=0,c_{\mathrm{e}}\vert_{x=L^-}=c_{\mathrm{e}}\vert_{x=0^{\mathrm{sep}}},c_{\mathrm{e}}\vert_{x=L^{\mathrm{sep}}}=c_{\mathrm{e}}\vert_{x=L^+}$
	$\dfrac{\partial c_{\mathrm{e}}^{\mathrm{sep}}}{\partial t}(x,t)=\dfrac{\partial}{\partial x}\left[D_{\mathrm{e}}\dfrac{\partial c_{\mathrm{e}}^{\mathrm{sep}}}{\partial x}(x,t)\right]$
	$\varepsilon_{\mathrm{e}}^{-}\left.\dfrac{\partial c_{\mathrm{e}}}{\partial x}\right\vert_{x=L^-}=\varepsilon_{\mathrm{e}}^{\mathrm{sep}}\left.\dfrac{\partial c_{\mathrm{e}}}{\partial x}\right\vert_{x=0^{\mathrm{sep}}},\varepsilon_{\mathrm{e}}^{\mathrm{sep}}\left.\dfrac{\partial c_{\mathrm{e}}}{\partial x}\right\vert_{x=L^{\mathrm{sep}}}=\varepsilon_{\mathrm{e}}^{+}\left.\dfrac{\partial c_{\mathrm{e}}}{\partial x}\right\vert_{x=L^+}$
交换电流密度	$i_0^{\pm}=k^{\pm}[c_{\mathrm{ss}}^{\pm}]^{\alpha_{\mathrm{c}}}[c_{\mathrm{e}}(c_{\mathrm{s,max}}^{\pm}-c_{\mathrm{ss}}^{\pm})]^{\alpha_{\mathrm{a}}}$
电极过电位	$\eta^{\pm}(t)=\dfrac{RT}{\alpha F}\sinh^{-1}\left(\dfrac{\mp I(t)}{2a\pm L\pm i_0^{\pm}(t)}\right)$
电解质电势	$\phi_{\mathrm{e}}^{+}(0^+,t)-\phi_{\mathrm{e}}^{-}(0^-,t)=\left(\dfrac{L^-}{2\kappa^-}+\dfrac{L^{\mathrm{sep}}}{\kappa^{\mathrm{sep}}}+\dfrac{L^+}{2\kappa^+}\right)$
	$I(t)+\dfrac{2RT}{F}(1-t_{\mathrm{c}}^0)\ln\dfrac{c_{\mathrm{e}}(0^+,t)}{c_{\mathrm{e}}(0^-,t)}$
终端电压	$V(t)=\eta^{+}(t)-\eta^{-}(t)+U^{+}(c_{\mathrm{ss}}^{+}(t))-U^{-}(c_{\mathrm{ss}}^{-}(t))-$ $\dfrac{R_{\mathrm{f}}^{-}}{a^-L^-}I(t)+\phi_{\mathrm{e}}^{+}(0^+,t)-\phi_{\mathrm{e}}^{-}(0^-,t)$
热平衡方程	$C_{\mathrm{c}}\dfrac{\mathrm{d}T_{\mathrm{c}}(t)}{\mathrm{d}t}=\dfrac{T_{\mathrm{s}}(t)-T_{\mathrm{c}}(t)}{R_{\mathrm{c}}}+\dot{Q}(t)$
	$C_{\mathrm{s}}\dfrac{\mathrm{d}T_{\mathrm{s}}(t)}{\mathrm{d}t}=\dfrac{T_{\mathrm{amb}}(t)-T_{\mathrm{s}}(t)}{R_{\mathrm{u}}}-\dfrac{T_{\mathrm{s}}(t)-T_{\mathrm{c}}(t)}{R_{\mathrm{c}}}$
产热率	$\dot{Q}(t)=I\left(V-E_{\mathrm{ocv}}+T_{\mathrm{c}}\dfrac{\mathrm{d}E_{\mathrm{ocv}}}{\mathrm{d}T}\right)$

2　多步参数辨识方法

与其他算法相比，鲸鱼算法有自己的优点，同时也存在易陷入局部最优的缺点。对此，采用对立学习策略和 Levy 变异改进算法，针对模型参数辨

识，并结合改进鲸鱼算法 OLWOA(whale optimazation algorithm based on oppositional learning strategy and Levy mutation)和阿伦尼乌斯定律，提出 1 种数据驱动的 EM 多步参数识别方法。

2.1 改进鲸鱼算法

改进鲸鱼算法是在 WOA[17]的基础上结合对立学习策略和 Levy 变异由 4 个部分组成：①气泡网攻击；②包围猎物；③对立学习策略；④Levy 变异。在鲸鱼群体中，气泡网攻击和包围猎物总是同时发生，故引入发生概率 P 来决定个体的行为，P 一般取 0.5。

2.1.1 气泡网攻击

当产生的随机数大于 P 时，鲸鱼发起气泡网攻击，其数学模型为

$$\boldsymbol{X}_i^{t+1}=\left|\boldsymbol{X}_{\text{best}}^t-\boldsymbol{X}_i^t\right|\mathrm{e}^{bl}\cos(2\pi l)+\boldsymbol{X}_{\text{best}}^t \tag{2}$$

式中：t 为迭代次数；$\boldsymbol{X}_{\text{best}}^t$ 为最优鲸鱼位置；$\boldsymbol{X}_i^t$ 为第 i 只鲸鱼位置；b 为限定对数螺旋形状的常数；l 为随机数，$l\in[-1, 1]$。

2.1.2 包围猎物

当产生的随机数小于等于 P 时，鲸鱼包围猎物，可以选择向最优鲸鱼或是随机鲸鱼游动，这 2 种行为分别称为收缩包围和搜索捕食。它们的不同之处在于前者向最优鲸鱼收缩，旨在收缩解空间，后者在解空间中随机搜索，增加候选解的随机性，且不会改变解空间的范围。

(1)收缩包围。鲸鱼在收缩包围时向着最优个体包围，其数学模型为

$$\boldsymbol{X}_i^{t+1}=\boldsymbol{X}_{\text{best}}^t-\boldsymbol{A}\left|\boldsymbol{C}\boldsymbol{X}_{\text{best}}^t-\boldsymbol{X}_i^t\right| \tag{3}$$

$$\begin{cases}\boldsymbol{A}=2\boldsymbol{a}\boldsymbol{r}_1-a\\ \boldsymbol{C}=2\boldsymbol{r}_2\end{cases} \tag{4}$$

$$|a|=2-2t/t_{\max} \tag{5}$$

式中：$\boldsymbol{A}$、$\boldsymbol{C}$ 为系数向量；$\boldsymbol{r}_1$、$\boldsymbol{r}_2$ 为[0, 1]之间的随机向量；$\boldsymbol{a}$ 为收敛因子向量，随迭代次数从 2 线性减少到 0；$t_{\max}$ 为最大迭代次数。特别地，当 $\boldsymbol{A}$ 的模小于 1 时，鲸鱼执行收缩包围。

(2)搜索捕食。当 $\boldsymbol{A}$ 的模大于等于 1 时，鲸鱼搜索捕食，与收缩包围类似，不同在于采用随机鲸鱼 $\boldsymbol{X}_{\text{rand}}^t$ 替换最优个体 $\boldsymbol{X}_{\text{best}}^t$，即

$$\boldsymbol{X}_i^{t+1}=\boldsymbol{X}_{\text{rand}}^t-\boldsymbol{A}\left|\boldsymbol{C}\boldsymbol{X}_{\text{rand}}^t-\boldsymbol{X}_i^t\right| \tag{6}$$

2.1.3 对立学习策略

文献[18]指出，初始种群的好坏影响智能优化算法的求解精度和收敛速度。WOA 采用随机方法产生初始群体，不能保证种群多样性，故引入对立学习策略[19]。假设在$[x_{\min}, x_{\max}]$上存在点 x，则 x 的对立点为 $ox=x_{\min}+x_{\max}-x$，将其扩展到高维空间。对立学习策略的具体步骤如图 3 所示，其不仅被用于初始化种群，也被用于迭代更新过程，其中，X_i^j 为第 i 个个体的第 j 维值，$X_{\max}^j$、$X_{\min}^j$ 分别为个体第 j 维的上、下限。

```
算法1 对立学习策略
设置种群规模N
 for i=1to N do
    for j=1 to d do
        OX_i^j=X_min^j+X_max^j-X_i^j
    end if
 end if
合并X(N) ∪ OX(N),从中选出适应度较优的前N个
个体作为对立学习结果
```

图 3 对立学习策略伪代码

Fig. 3 Pseudo-code of oppositional learning strategy

2.1.4 Levy 变异

Levy 飞行是 1 种长短步相间的飞行方式，可以扩大动物的行为轨迹范围，增加捕获猎物的概率，据此衍生的 Levy 变异[20]可以提升寻优算法的全局寻优能力。将这种变异方式用于优化领域，可以得到更新公式为

$$\boldsymbol{X}_i^{t+1}=\boldsymbol{X}_i^t+\alpha\otimes\text{Levy}(\beta) \tag{7}$$

式中：α 为步长比例因子；$\otimes$ 表示直积；Levy(β)为服从参数为 β 的 Levy 分布随机数，计算方法为

$$\text{Levy}(\beta)\sim\frac{u}{|v|^{1/\beta}} \tag{8}$$

式中，u、v 均服从正态分布，定义为

$$u\sim N(0,\sigma_u^2),\sigma_u=\left\{\frac{\Gamma(1+\beta)\sin(\beta\pi/2)}{\Gamma[(1+\beta)/2]\beta\cdot 2^{\frac{\beta-1}{2}}}\right\}^{1/\beta} \tag{9}$$

$$v\sim N(0,\sigma_v^2),\sigma_v=1 \tag{10}$$

β 的取值范围一般为(1, 3]，本文中 β 取 1.5。在算法中引入变异概率 P_1 来决定个体是否执行变异。当随机数小于 P_1 时，个体触发 Levy 变异。

OLWOA 通过对立学习策略和 Levy 变异提高了算法的收敛速度和跳出局部最优的能力，其总体流程如图 4 所示。

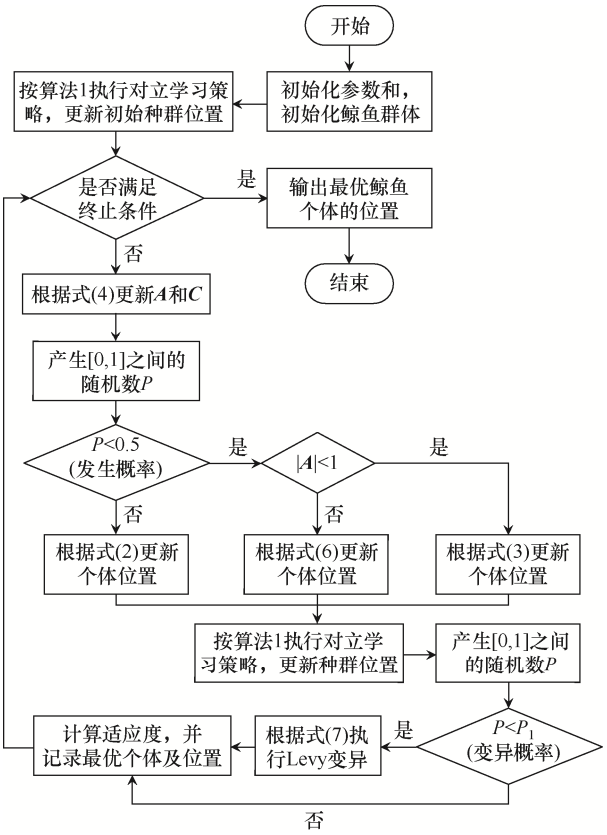


图 4　OLWOA 流程

Fig. 4 Flow chart of OLWOA

2.2 多步参数辨识框架

2.2.1 适应度函数

适应度函数用于评估参数集的质量，是参数辨识过程中的必要环节，对识别结果有显著影响。适应度函数的第 1 项 F_V 是模型仿真电压 $\hat{V}(t)$ 与实验测量电压 $V(t)$ 的均方根误差，表示为

$$F_V=\sqrt{\frac{1}{N_t}\sum_{t=1}^{N_t}[V(t)-\hat{V}(t)]^2} \tag{11}$$

式中，N_t 为数据集的数据点数。

利用式(11)，OLWOA 使模型电压拟合测量电压。适应度函数的第 2 项 F_T 是模型温度 $\hat{T}(t)$ 与电池表面测量温度 $T(t)$ 的均方根误差，表示为

$$F_T=\sqrt{\frac{1}{N_t}\sum_{t=1}^{N_t}[T(t)-\hat{T}(t)]^2} \tag{12}$$

利用式(12)，OLWOA 使模型温度拟合电池表面测量温度。适应度函数 F_M 由上述 2 项组成，即

$$F_M=\sum_{n=1}^{N_\mathrm{p}}(\omega_{V_n}F_V-\omega_{T_n}F_T) \tag{13}$$

式中：N_p 为采用多组训练数据辨识参数时的数据组数；ω_{V_n}、ω_{T_n} 为对应项的权重。权重的选择影响辨识结果，在优化过程中通过保持各项有相同数量级来确定权重取值。

2.2.2 多步参数辨识

鉴于 SPMET 中的耦合关系满足阿伦尼乌斯定律，式(1)中的参数活化能可以通过参数拟合获得。据此提出多步参数辨识框架，如图 5 所示。

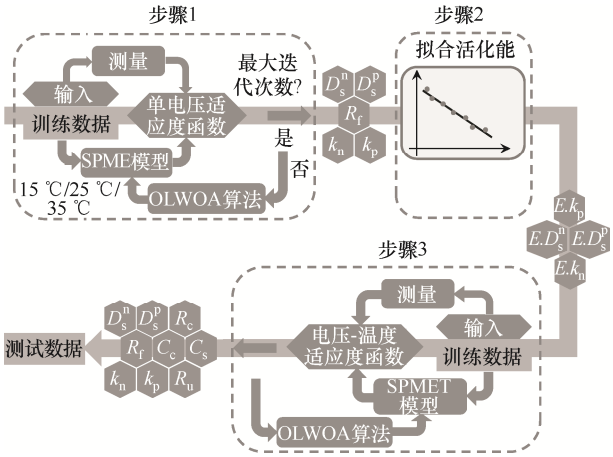


图 5　多步参数辨识过程示意

Fig. 5 Schematic of multi-step parameter identification process

步骤 1 分别利用 15、25、35 ℃下 1C 恒流放电数据，对 SPMET 的待辨识参数进行识别，适应度函数采用式(11)。

步骤 2 根据步骤 1 中辨识得到的参数值结合阿伦尼乌斯公式拟合参数活化能。对式(1)进行变形处理，得到拟合直线形式为

$$\ln X_i=-\frac{\bar{E}_l}{R}\frac{1}{T}+\frac{\bar{E}_l}{R}\frac{1}{T_\mathrm{ref}}+\ln X_{i,\mathrm{ref}} \tag{14}$$

横坐标表示温度的倒数，纵坐标表示以 e 为底的对数参数，得到拟合曲线斜率 k，则拟合参数活

化能满足 $\bar{E}=-kR$。

步骤 3 根据前 2 步结果设置参数活化能，利用 15、25、35 ℃下的恒流数据和适应度函数式(13)，对 SPMET 的模型参数进行识别。所得参数辨识结果再结合步骤 2 中的拟合参数活化能即 可获得 SPMET 模型参数。

3 验证与讨论

SPMET 的模型参数分为几何参数、性能参数和固定参数。其中：几何参数包括正、负极及隔膜厚度、颗粒半径等；性能参数包括固液相扩散系数、正负极反应速率等；固定参数包括摩尔气体常数、法拉第常数等，无需辨识。实验使用 LG NMC18650 电池，电压工作范围为 2.75~4.20 V。拆解电池测得一部分几何参数，包括正、负极片和隔膜的厚度、极片长与宽等。考虑 NMC/石墨锂电池，通过文献[14]的方法确定其正、负极开路电压 U_{ocv}^{+}、U_{ocv}^{-} 分别为

$$\begin{aligned}U_{\mathrm{ocv}}^{+}=&-0.809x+4.487\ 5-0.042\ 8\cdot\\&\tanh[18.513\ 8(x-0.554\ 2)]-\\&17.732\ 6\tanh[15.789(x-0.311\ 7)]+\\&17.584\ 2\tanh[15.930\ 8(x-0.312)]\end{aligned}\tag{15}$$

$$\begin{aligned}U_{\mathrm{ocv}}^{-}=&1.979\ 3\mathrm{e}^{-39.363\ 1x}+0.248\ 2-0.090\ 9\cdot\\&\tanh[29.853\ 8(x-0.123\ 4)]-\\&0.044\ 78\tanh[14.915\ 9(x-0.276\ 9)]-\\&0.020\ 5\tanh[30.444\ 4(x-0.610\ 3)]\end{aligned}\tag{16}$$

式中，$x=c_{\mathrm{ss}}^{\pm}/c_{x,\max}^{\pm}$。电解液考虑标准 1 mol/L 的 $\mathrm{LiPF_6}$ 溶液，通过文献[21]的方法确定电解液扩散系数 $D_{\mathrm{e}}(c_{\mathrm{e}})$ 和电解液电导率 $\kappa_{\mathrm{e}}(c_{\mathrm{e}})$ 分别为

$$\begin{aligned}D_{\mathrm{e}}(c_{\mathrm{e}})=&8.794\times10^{-11}(c_{\mathrm{e}}/1000)^2-3.972\times\\&10^{-10}(c_{\mathrm{e}}/1\,000)+4.862\times10^{-10}\end{aligned}\tag{17}$$

$$\begin{aligned}\kappa_{\mathrm{e}}(c_{\mathrm{e}})=&0.129\ 7(c_{\mathrm{e}}/1\,000)^3-2.51\cdot\\&(c_{\mathrm{e}}/1\,000)^{1.5}+3.329(c_{\mathrm{e}}/1\,000)\end{aligned}\tag{18}$$

除上述参数外，其他已知参数见表 2。

考虑耦合热模型的情况，依赖温度的参数应通过实验数据辨识获得。这些参数一部分来自于电化学模型，一部分来自于热模型，具体待辨识参数及其范围见表 3。

表 2 LG NMC18650 锂电池已知参数[14,21-22]

Tab. 2 Known parameters of LG NMC18650 lithium battery[14,21-22]

参数	数值		
	负极	隔膜	正极
L/m	76×10^{-6}	12×10^{-6}	85×10^{-6}
ε_{s}	0.750		0.665
$c_{\mathrm{s,max}}$/(mol·m^{-3})	33 133		63 104
t_{c}^{0}	0.259 4	0.259 4	0.259 4
F/(C·mol^{-1})	96 485	96 485	96 485
Brug	1.5	1.5	1.5
R_{s}/m	5.86×10^{-6}		5.22×10^{-6}
ε_{e}	0.250	0.470	0.335
c_{e}/(mol·m^{-3})	1 000	1 000	1 000
R/(J·mol^{-1}·K^{-1})	8.314 4	8.314 4	8.314 4
α	0.5	0.5	0.5

表 3 待辨识参数及范围[15,23-26]

Tab. 3 Parameters to be identified and their ranges[15,23-26]

参数	数值范围	参数	数值范围
D_{s}^{-}/(m^2·s^{-1})	10^{-14}~10^{-13}	k^{-}/(m$^{2.5}$·mol$^{-0.5}$·s^{-1})	10^{-12}~10^{-10}
D_{s}^{+}/(m^2·s^{-1})	10^{-15}~10^{-14}	k^{+}/(m$^{2.5}$·mol$^{-0.5}$·s^{-1})	10^{-11}~10^{-10}
$E.D_{\mathrm{s}}^{-}$/(J·mol^{-1})	10^{4}~10^{5}	C_{c}/(J·K^{-1})	1~100
$E.D_{\mathrm{s}}^{+}$/(J·mol^{-1})	10^{4}~10^{5}	C_{s}/(J·K^{-1})	1~100
$E.k^{-}$/(J·mol^{-1})	10^{4}~10^{5}	R_{c}/(K·W^{-1})	0.5~5.0
$E.k^{+}$/(J·mol^{-1})	10^{4}~10^{5}	R_{u}/(K·W^{-1})	1~20
R_{f}/(Ω·m^2)	10^{-3}~10^{-2}		

参数辨识所需的数据集分为训练数据和测试数据，见表 4，其中训练数据用于辨识模型参数，测试数据用于验证辨识结果。

表 4 实验数据集

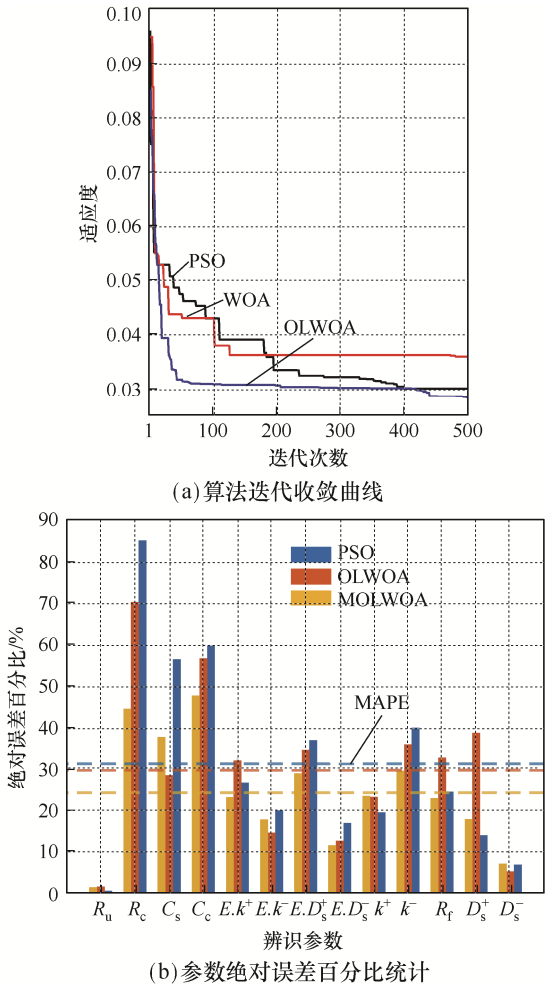
Tab. 4 Experimental dataset

载入工况	数据类型	持续时间/s
0.5C 恒流放电	测试数据	7 111
城市道路循环测试	测试数据	1 370
1C 恒流放电	训练数据	3 494
动态应力测试	测试数据	360
2C 恒流放电	测试数据	1 661

3.1 数值验证

由于难以获取模型参数的真实值，使用虚拟电

池对多步参数辨识方法进行数值验证，参数在表 3 的数值范围内随机取值。辨识数据集在表 4 所示的载入工况下由虚拟电池模型仿真生成，数值验证结果如图 6 所示。



(a)算法迭代收敛曲线

(b)参数绝对误差百分比统计

图 6　数值验证

Fig. 6 Numerical verification

以 PSO 为比较基准，展现 OLWOA 算法的快速收敛性和高识别效率。为了较公平地比较算法性能，采用相同的适应度函数，并调整算法参数以尽可能保证每个算法具有最佳性能。分别使用 PSO、WOA 和 OLWOA 算法对模型参数进行辨识，其迭代收敛曲线如图 6(a)所示。从图 6(a)中可知，WOA 算法比 PSO 算法收敛速度更快，但在约 150 次迭代后收敛停滞，收敛曲线趋近于一条水平直线，即当前算法最优解并不随算法运行而发生变化，而 PSO 算法收敛曲线表明尚有更优解并未被 WOA 算法发现，这说明 WOA 算法陷入局部最优。OLWOA 算法拥有更快的收敛速度，适应度较 WOA、PSO 算法进一步降低，表明 OLWOA 算法可以更有效地辨识参数，原因为：首先采用对数螺旋方程更新个体位置，使算法快速收敛；其次引入的对立学习策略和 Levy 变异提高了算法在复杂非线性系统中的全局寻优能力。比较结果表明 OLWOA 算法在 SPMET 的模型参数辨识方面具有较高的收敛速度。

为了验证多步参数辨识框架对参数识别精度的影响，比较以下 2 种基于 OLWOA 算法的参数辨识方法。第 1 种方法是以式(13)为适应度函数的 OLWOA 参数辨识方法；第 2 种方法为基于改进鲸鱼算法的多步参数辨识方法 MOLWOA (multi-step OLWOA)，是在第 1 种方法的基础上结合 3.2 节提出的多步参数辨识框架。表 5 总结 PSO、OLWOA 和 MOLWOA 方法识别参数的绝对百分比误差 APE(absolute percentage error)，统计如图 6(b)所示，图中虚线表示参数的平均绝对百分比误差 MAPE (mean absolute percentage error)。APE 和 MAPE 的计算公式为

$$\mathrm{APE}=\frac{|y-\hat{y}|}{|y|}\times 100\% \tag{19}$$

$$\mathrm{MAPE}=\frac{1}{n}\sum_{i=1}^{n}\frac{|y_i-\hat{y}_i|}{|y_i|}=\frac{1}{n}\sum_{i=1}^{n}\mathrm{APE}_i \tag{20}$$

式中：y 为参数的真实值；$\hat{y}$ 为参数的辨识结果；MAPE 为对所有待辨识参数的 APE 求平均值的结果。APE 与 MAPE 用于表示辨识参数结果与真实值的偏离程度，表征辨识结果的可信度，值越小表明辨识结果越可信。由图 6(b)可知，MAPE 从 PSO 下的 31.0%降到 OLWOA 下的 29.5%，再降到 MOLWOA 下的 23.8%，这得益于在步骤 1 和步骤 2 中拟合参数活化能。该操作一方面降低了参数活化能的误差，另一方面减少了步骤 3 中的辨识参数数量，降低了参数的辨识难度。MAPE 的降低表明 MOLWOA 方法在 SPMET 的模型参数识别方面具有优势，证明了多步参数辨识方法的辨识精度。

表 5 PSO、OLWOA 和 MOLWOA 方法参数辨识结果

Tab. 5 Parameter identification results obtained using PSO, OLWOA and MOLWOA methods

参数	虚拟值	APE/%		
		PSO	OLWOA	MOLWOA
D_s^-/(m²·s⁻¹)	3.3×10^{-14}	6.61	4.94	6.84
D_s^+/(m²·s⁻¹)	4×10^{-15}	13.65	38.46	17.48
k^-/(m$^{2.5}$·mol$^{-0.5}$·s^{-1})	6.72×10^{-12}	39.71	35.72	29.35
k^+/(m$^{2.5}$·mol$^{-0.5}$·s^{-1})	3.54×10^{-11}	19.10	22.84	23.10
ED_s^-/(J·mol⁻¹)	10^4	16.61	12.36	11.23
ED_s^+/(J·mol⁻¹)	99.894×10^3	36.67	34.40	28.70
Ek^-/(J·mol⁻¹)	40.971×10^3	19.60	14.29	17.40
Ek^+/(J·mol⁻¹)	78.576×10^3	26.48	31.80	22.80
C_c/(J·K⁻¹)	62.7	59.49	56.41	47.46
C_s/(J·K⁻¹)	5	56.18	28.24	37.50
R_c/(W·K⁻¹)	1.67	85.03	69.94	44.27
R_u/(W·K⁻¹)	11.12	0.36	1.44	1.17
R_f/(Ω·m²)	0.001	24.10	32.50	22.50

3.2 工况验证

在数值验证后，根据采样数据和 MOLWOA 方法辨识电池参数进行实验验证。实验搭建了一套电池测试系统，包括连接单体的 LANBTS 电池测试仪、测温辅助设备(BTU-2018)、控制 PC 和 ESPEC 环境温箱等。实验中，电池被置于恒定温度分别为 15、25、35 ℃的环境温箱中，对照表 4 的工况进行测试，充电均采用标准恒流恒压充电，并实时测量电流、电压和表面温度。

据第 2 节所述多步参数辨识方法，步骤 2 得到的参数活化能拟合曲线如图 7 所示。图(a)~(d)分别表示参数 k^-、k^+、D_s^-、D_s^+ 的活化能拟合曲线，其值由曲线斜率结合式(14)得出，表 6 给出具体参数辨识结果。完整参数辨识耗时约 16 h，按 500 次迭代次数计算，平均每次迭代耗时约 2 min。为了证明参数集的有效性，需进行恒流放电工况和动态放电工况的验证。

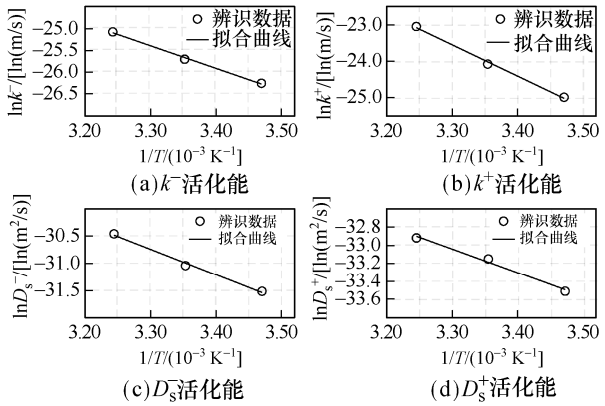


图 7 参数活化能拟合曲线

Fig. 7 Fitted curves for parameter activation energy

表 6 电池参数辨识结果

Tab. 6 Identification results of battery parameters

参数	MOLWOA 辨识结果
D_s^-/(m²·s⁻¹)	3.08×10^{-14}
D_s^+/(m²·s⁻¹)	4.46×10^{-15}
ED_s^-/(J·mol⁻¹)	38.83×10^3
ED_s^+/(J·mol⁻¹)	21.70×10^3
Ek^-/(J·mol⁻¹)	43.12×10^3
Ek^+/(J·mol⁻¹)	71.44×10^3
R_f/(Ω·m²)	0.006 7
k^-/(m$^{2.5}$·mol$^{-0.5}$·s^{-1})	5.87×10^{-12}
k^+/(m$^{2.5}$·mol$^{-0.5}$·s^{-1})	2.26×10^{-11}
C_c/(J·K⁻¹)	87.12
C_s/(J·K⁻¹)	37.5
R_c/(K·W⁻¹)	2.67
R_u/(K·W⁻¹)	14.37

有效且准确的参数识别结果可使模型的预测误差更小。图 8 为 25 ℃下 0.5C、2C 恒流放电工况验证曲线，由图 8 可见，0.5C、2C 放电工况下的电压最大绝对误差分别为 40、24 mV，均方根误差分别为 13、20 mV；温度最大绝对误差分别为 0.37、0.72 ℃，均方根误差分别为 0.18、0.40 ℃。误差表明模型仿真数据较好地符合实际测量数据。

锂电池在使用过程中以动态电流放电，所以有必要验证动态放电工况。测试中选择的动态工况为城市道路循环测试 UDDS(urban dynamometer driving schedule)和动态应力测试 DST(dynamic stress test)。图 9 为 25 ℃下 DST、UDDS 放电工况验证曲线，据图 9 可知，DST、UDDS 工况下的电压最大绝对误差分别为 66、88 mV，均方根误差分别为 22、26 mV；温度最大绝对误差分别为 0.41、0.34 ℃，均方根误差分别为 0.22、0.27 ℃。与恒流放电工况相比，模型预测误差存在一定程度的增

大，但仍能较好地符合实际测量数据。

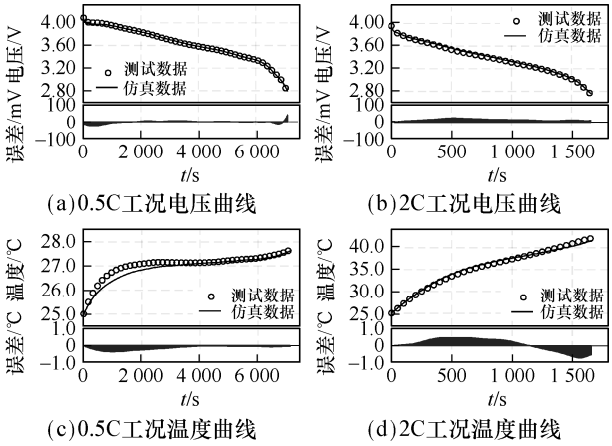


图 8　25 ℃下恒流工况电压与温度曲线

Fig. 8 Voltage and temperature curves under constant-current working condition at 25 ℃

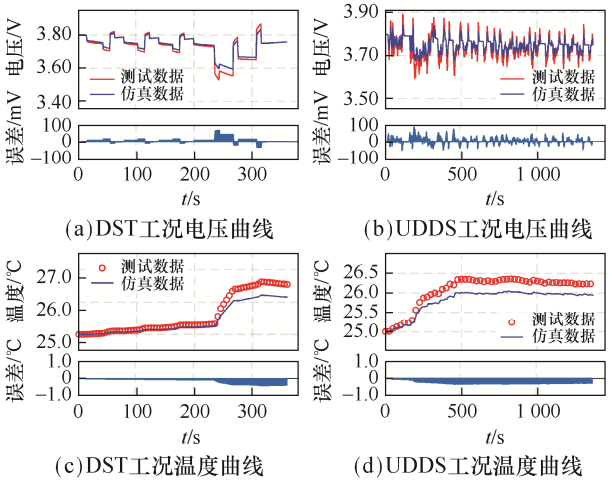


图 9　25 ℃下动态工况电压与温度曲线

Fig. 9 Voltage and temperature curves under dynamic working condition at 25 ℃

电压与温度的均方根误差统计如图 10 所示。由图 10 可见，误差随工况变化明显，受温度影响并不显著。相比恒流工况下，动态工况下的电压均方根误差大，增大约 8 mV；温度均方根误差百分比也大，增大约 10%，表明辨识参数泛化能力不强。工况验证发现，电压均方根误差维持在 10~30 mV 之间，温度均方根误差维持在 0.2~0.5 ℃之间，取得了良好的预测效果，证明了辨识参数集的有效性。

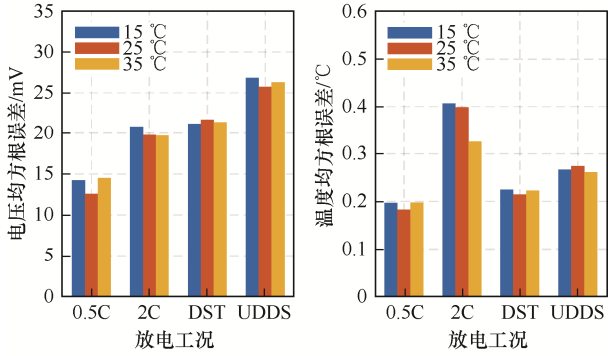


图 10　电压与温度的均方根误差统计

Fig. 10 Statistics of RMSE for voltage and temperature

4　结语

本文旨在开发 1 种锂电池电化学−热耦合模型离线参数辨识方法，将含电解液动力学的单粒子模型和集总热模型耦合建立 SPMET，并结合模型耦合特点提出 MOLWOA。与其他模型参数识别方法相比，MOLWOA 方法表现出更快的辨识速度和更高的识别精度。最后，MOLWOA 方法实现对商用电池的参数辨识，并在不同工况下验证辨识结果的有效性。然而参数辨识采用的恒流数据过于理想，不符合电池使用时的复杂表现。鉴于变电流工况繁多，后续研究将着重分析变电流工况对参数辨识的影响，并寻找对参数辨识更为有利的变电流工况。

参考文献：

[1] Li Weihan, Limoge D W, Zhang Jiawei, et al. Estimation of potentials in lithium-ion batteries using machine learning models [J]. IEEE Transactions on Control Systems Technology, 2022, 30(2): 680-695.

[2] Li Junfu, Wang Dafang, Deng Lei, et al. Aging modes analysis and physical parameter identification based on a simplified electrochemical model for lithium-ion batteries [J]. Journal of Energy Storage, 2020, 31: 101538.

[3] Li Weihan, Fan Yue, Ringbeck F, et al. Unlocking electrochemical model-based online power prediction for lithium-ion batteries via Gaussian process regression [J]. Applied Energy, 2022, 306: 118114.

[4] Ringbeck F, Garbade M, Sauer D U. Uncertainty-aware

state estimation for electrochemical model-based fast charging control of lithium-ion batteries [J]. Journal of Power Sources, 2020, 470: 228221.

[5] Schmalstieg J, Rahe C, Ecker M, et al. Full cell parameterization of a high-power lithium-ion battery for a physico-chemical model: part I. physical and electrochemical parameters [J]. Journal of the Electrochemical Society, 2018, 165(16): A3799-A3810.

[6] Schmalstieg J, Sauer D U. Full cell parameterization of a high-power lithium-ion battery for a physico-chemical model: part II. thermal parameters and validation [J]. Journal of the Electrochemical Society, 2018, 165(16): A3811-A3819.

[7] Deng Zhongwei, Deng Hao, Yang Lin, et al. Implementation of reduced-order physics-based model and multi-parameters identification strategy for lithium-ion battery [J]. Energy, 2017, 138: 509-519.

[8] 马锐, 贾学翠, 张永康, 等. 基于三次样条插值法的储能锂电池建模与参数辨识[J]. 电源学报, 2023, 21(1): 133-141.
Ma Rui, Jia Xuecui, Zhang Yongkang, et al. Modeling and parameters identification of Li-ion battery for energy storage based on cubic spline interpolation method [J]. Journal of Power Supply, 2023, 21(1): 133-141. (in Chinese)

[9] Pang Hui, Mou Lianjing, Guo Long, et al. Parameter identification and systematic validation of an enhanced single-particle model with aging degradation physics for Li-ion batteries [J]. Electrochimica Acta, 2019, 307: 474-487.

[10] 许志华. 锂电池的分数阶建模及状态估计方法研究[J]. 电源学报, 2025, 23(2): 266-273.
Xu Zhihua. Fractional-order modeling and state estimation method for lithium battery [J]. Journal of Power Supply, 2025, 23(2): 266-273. (in Chinese)

[11] Fan Guodong. Systematic parameter identification of a control-oriented electrochemical battery model and its application for state of charge estimation at various operating conditions [J]. Journal of Power Sources, 2020, 470: 228153.

[12] Doyle M, Newman J, Gozdz A S, et al. Comparison of modeling predictions with experimental data from plastic lithium ion cells [J]. Journal of the Electrochemical Society, 1996, 143(6): 1890-1903.

[13] Moura S J, Argomedo F B, Klein R, et al. Battery state estimation for a single particle model with electrolyte dynamics [J]. IEEE Transactions on Control Systems Technology, 2017, 25(2): 453-468.

[14] Chen Changhui, Brosa Planella F, O'Regan K, et al. Development of experimental techniques for parameterization of multi-scale lithium-ion battery models [J]. Journal of the Electrochemical Society, 2020, 167(8): 080534.

[15] Lin Xinfan, Perez H E, Mohan S, et al. A lumped-parameter electro-thermal model for cylindrical batteries [J]. Journal of Power Sources, 2014, 257: 1-11.

[16] 韩甜, 时玮, 赵杨梅, 等. 圆柱型锂离子电池三维分层热耦合模型研究[J]. 电源学报, 2021, 19(5): 165-171.
Han Tian, Shi Wei, Zhao Yangmei, et al. Research on 3D layered thermal coupling model of cylindrical lithium-ion battery [J]. Journal of Power Supply, 2021, 19(5): 165-171. (in Chinese)

[17] Mirjalili S, Lewis A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.

[18] Haupt R L, Haupt S E. Practical Genetic Algorithms[M]. New York: John Wiley & Sons, 2003: 1-25.

[19] Tizhoosh H R. Opposition-based learning: a new scheme for machine intelligence [C]// International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06). Vienna, Austria, 2005: 695-701.

[20] 梁倩. 基于反向精英保留和 Levy 变异的多目标鲸鱼优化算法[J]. 现代计算机, 2021, 27(18): 25-31.
Liang Qian. Multi-objective whale optimization algorithm based on reverse elite retention and Levy mutation [J]. Modern Computer, 2021, 27(18): 25-31. (in Chinese)

[21] Nyman A, Behm M, Lindbergh G. Electrochemical characterisation and modelling of the mass transport phenomena in $LiPF_6$-EC-EMC electrolyte [J]. Electrochimica Acta, 2008, 53(22): 6356-6365.

[22] Landesfeind J, Gasteiger H A. Temperature and concentration dependence of the ionic transport properties of lithium-ion battery electrolytes [J]. Journal of the Electro-

chemical Society, 2019, 166(14): A3079-A3097.

[23] Smekens J, Paulsen J, Yang W, et al. A modified multiphysics model for lithium-ion batteries with a $Li_xNi_{1/3}Mn_{1/3}Co_{1/3}O_2$ electrode [J]. Electrochimica Acta, 2015, 174: 615-624.

[24] Rheinfeld A, Sturm J, Noel A, et al. Quasi-isothermal external short circuit tests applied to lithium-ion cells: part II. modeling and simulation [J]. Journal of the Electrochemical Society, 2019, 166(2): A151-A177.

[25] Nileshwar P R, McGordon A, Ashwin T R, et al. Parametric optimization study of a lithium-ion cell [J]. Energy Procedia, 2017, 138: 829-834.

[26] Geifes F, Bolsinger C, Mielcarek P, et al. Determination of the entropicheat coefficient in a simple electro-thermal lithium-ion cell model with pulse relaxation measurements and least squares algorithm [J]. Journal of Power Sources, 2019, 419: 148-154.



赵家城

作者简介：

赵家城(1998—)，男，硕士研究生。研究方向：锂电池智能充电管理。E-mail：zhaojiacheng1@outlook.com。

孙坚(1964—)，男，通信作者，硕士，教授。研究方向：新能源计量和智能管理。E-mail：1955692303@qq.com。

徐红伟(1972—)，男，博士，副教授。研究方向：锂电池智能管理和自动化装置。E-mail：xhw@cjlu.edu.cn。

(责任编辑：孙美菊)

(上接第 282 页)



路玲

作者简介：

路玲(1993—)，女，通信作者，硕士，讲师。研究方向：新能源汽车电驱动系统热设计。E-mail：849402646@qq.com。

汪缤缤(1991—)，女，硕士，讲师。研究方向：材料组织性能及流体动力学研究。E-mail：1151105263@qq.com。

胡健(1985—)，男，硕士，副教授。研究方向：机械传动与 NVH 及机电产品再资源化技术与方法。E-mail：253984415@qq.com。

秦鹏(1991—)，男，硕士，讲师。研究方向：先进制造技术。E-mail：925709170@qq.com。

(责任编辑：陈国珍)