DOI：10.13234/j.issn.2095-2805.2025.3.363 **中图分类号**：TM912.9 **文献标志码**：A

基于BP-多时间尺度UKF优化算法的SOC估计

白俊琦[1,2](中国电源学会会员)，贤燕华[1,2]
(1.广西类脑计算与智能芯片重点实验室，广西师范大学电子与信息工程学院，桂林 541004；
2.广西高校非线性电路与光通信重点实验室，广西师范大学电子与信息工程学院，桂林 541004)

摘要：针对组合算法在初值标定存在偏差时，荷电状态SOC(state-of-charge)估计效果不理想的问题，提出了一种基于BP-多时间尺度UKF优化算法的SOC预测方法。该方法将多时间尺度理论应用到组合算法中，首先，利用多时间尺度无迹卡尔曼滤波器UKF(unscented Kalman filter)初步得到SOC。其次，构建BP模型对滤波算法产生的数据进行训练，并利用BP算法良好的自学习和适应能力进行误差补偿，进一步降低误差。所提算法通过多时间尺度扩展卡尔曼滤波器EKF(extended Kalman filter)建模，不仅在一定程度上降低了参数变化引起的SOC估计误差，同时也为误差补偿提供了可靠数据，提高了模型的泛化能力，从而降低了数据驱动部分对数据的依赖程度。仿真结果表明，该算法对数据量依赖小且在估计精度、泛化能力和鲁棒性方面均表现优异，其均方根误差与平均绝对误差小于1%，最大绝对误差为1%左右。

关键词：荷电状态；多时间尺度；BP神经网络；组合算法；锂电池

State-of-charge Estimation Based on BP-Multi-timescale UKF Optimization Algorithm

BAI Junqi[1,2], *Member*, *CPSS*, XIAN Yanhua[1,2]
(1. Guangxi Key Laboratory of Brain-inspired Computing and Intelligent Chips, School of Electronic and Information Engineering, Guangxi Normal University, Guilin 541004, China; 2. Key Laboratory of Nonlinea Circuits and Optical Communications (Guangxi Normal University), Education Department of Guangxi Zhuang Autonomous Region, School of Electronic and Information Engineering, Guilin 541004, China)

Abstract: Aimed at the problem that the state-of-charge(SOC) of batteries estimated by a combination algorithm is not ideal when there exits deviation from the initial value, a BP-multi-timescale unscented Kalman filter(UKF) optimization algorithm is proposed in this paper, which applies the multi-timescale theory to the combination algorithm. First, the multi-timescale UKF is used to preliminarily estimate the SOC value. Then, a BP model is constructed to train the data generated by the filtering algorithm, and the self-learning and adaptive capability of the BP algorithm is used to compensate and further reduce the error. The multi-timescale extended Kalman filter(EKF) modeling can not only reduce the SOC estimation error caused by changes in parameters, but also provide reliable data for error compensation, thus improving the model's generalization capability and reducing the data dependence by the data-driven part. Simulation results show that the proposed algorithm depends on less data, and it outperforms other algorithms in terms of estimation accuracy, generalization capability and robustness. The root mean square error and mean absolute error are less than 1%, and the maximum absolute error is about 1%.

Keywords: State-of-charge(SOC); multiple timescales; BP neural network; combination algorithm; lithium battery

锂离子电池作为电动汽车的关键部件，拥有能量密度高、开路电压大、输出功率大、无记忆效应等优点，广泛应用于电子产品、军工产品、航空产品等领域[1]。电源管理系统为合理高效地使用锂离子电池提供了可靠的保障，其中锂离子电池的荷电状态SOC(state-of-charge)是电源管理预测的关键参

收稿日期：2022-04-18；**修回日期**：2022-09-18；**录用日期**：2022-09-27；**网络首发日期**：2022-12-02
基金项目：国家自然科学基金资助项目(61976063)
This work is supported by National Natural Science Foundation of China under the grant 61976063

数，准确预测 SOC 可以提供行驶里程的重要信息，也可为防止电池过充过放和电池组管理维护提供重要依据。由于锂离子电池为封闭系统，只能通过外部的物理特性估算 SOC[2]，因此锂离子电池 SOC 准确估计已成为研究的热点。

目前主流的方法分为 3 类：直接计算法[3]、基于模型法[4]和数据驱动法[5]。安时积分法和开路电压法是简单的直接计算法，前者容易因误差累积而产生发散，后者使用条件苛刻不适合推广，二者均难以在电动车上使用。基于模型法通常基于等效电路模型或电化学模型，采用卡尔曼滤波器 KF(Kalman filter)、拓展卡尔曼滤波 EKF(extended Kalman filter)、无迹卡尔曼滤波器 UKF(unscented Kalman filter)[6]和移动水平估计 MHE(moving horizon estimation)等方法进行 SOC 估计，此类方法精度高、收敛快，但存在易受扰动、对建模精度要求高的缺点。

为克服建模精度的影响，众多文献提出基于不同时间尺度下 SOC 估算的新方法。文献[7-8]均基于多时间尺度建模，使用不同算法进行 SOC 估计，很大程度上克服了由于建模带来的估计误差，但仍存在易受不规则噪声影响、鲁棒能力有限等缺点。在数据驱动方法中，电池常被视为一个黑盒子，没有任何物理化学机制，通常使用智能算法，例如 BP 神经网络[9]、支持向量机[10]、高斯过程回归和长短时期记忆网络[11]等估计 SOC。此类算法具有适应性强和高度非线性匹配的优点，然而在实际应用中存在诸多局限：在数据量有限的情况下，缺乏电池模型约束，存在欠拟合或过拟合的风险[12]。

综上所述，单一 SOC 估计算法存在明显缺陷，无法兼顾多项指标，由此组合算法[13-20]应运而生。其中部分组合算法利用传统滤波方法与数据驱动算法优势的互补，在一定程度上提高了估计效果，但训练所需数据量大，与 SOC 初值标定存在偏差时算法的泛化能力、估计精度和整体稳定性等都变差。

鉴于此，本文提出一种基于 BP-多时间尺度 UKF 优化算法的 SOC 估计方法。通过对比实验，充分展示当存在初值标定偏差时，所提算法仍可保持优秀的估计精度，同时在泛化能力、鲁棒性方面表现优异，且数据驱动部分对数据量依赖小。

1 等效电路模型和多时间尺度离散化模型

1.1 等效电路模型

电池模型的选择对于准确估算 SOC 至关重要，由于 Rint 模型、一阶 RC 模型及 PNGV 模型的精度有限，二阶以上 RC 模型会明显增加模型计算量但提高的精度效果有限，故综合考虑电池模型的复杂度和精度，最终选用二阶 RC 等效电路模型，如图 1 所示。图中：U_{ocv}为电池的开路电压，通常随 SOC 非线性变化；R_0为电池的欧姆内阻；R_1和 C_1分别为极化电阻和极化电容；R_2和 C_2分别为扩散电阻和扩散电容；$I(t)$为流过的负载电流，可以通过电流传感器测得；U_1、U_2分别为 R_1、R_2的电压；U_0为端电压。

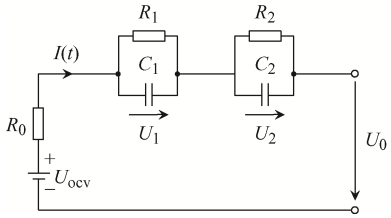


图 1 戴维南二阶 RC 电路模型

Fig. 1 Thevenin second-order RC circuit model

令 Z=SOC，使用 $g_{(Z)}$来描述 U_{ocv}与 SOC 之间关系。需要指出的是，$g_{(Z)}$为 SOC 的 N 次多项式，N 与采样点个数有关，其精度对于提高 SOC 预测至关重要。根据图 1 模型可推导出电池的状态方程和观测方程分别为

$$\begin{cases}\dfrac{\mathrm{d}U_1}{\mathrm{d}t}=\dfrac{-U_1(t)}{R_1C_1}+\dfrac{I(t)}{C_1}\\[2ex]\dfrac{\mathrm{d}U_2}{\mathrm{d}t}=\dfrac{-U_2(t)}{R_2C_2}+\dfrac{I(t)}{C_2}\\[2ex]Z_{k+1}=Z_k-\dfrac{\mu I_k T_{\mathrm{s}}}{Q_{\mathrm{n}}}\end{cases}\tag{1}$$

$$U_0 = g_{(Z)} - R_0 I(t) - U_1 - U_2 \tag{2}$$

式中：η 为库伦效率；T_s 为采样周期，T_s=1 s；Q_n 为电池容量。

1.2 多时间尺度离散化模型

由于 UKF 需在非线性离散化模型中应用，因此需将 1.1 节中的连续模型离散化。针对电池参数慢变与电池状态快变的特征，可分别从宏观与微观时间尺度进行预测。为方便表述，分别使用 k 和 l 作为宏观与微观时间尺度的时间指标，如 $t_{k,l}$ 表示任意微观 l 与宏观 k 时间尺度时刻，$t_{k,l} = t_{k,0} + lT_s$，其中，$t_{k,0} = t_{k-1,L}$；$l = 1,2,\cdots,L$；$k = 1,2,\cdots,\infty$。根据系统参数变化情况，来确定宏观仿真时间步数 k；在 k 与 k+1 的时间内，根据状态量的变化和 T_s 进而确定微观仿真时间步数 l。考虑到模型参数的特征，假设电池为时不变系统，且在每个周期 T_s 内恒定，可得到 U_1、U_2 的解析解分别为

$$\begin{cases} U_1[(l+1)T_s] = \\ \quad \exp\left(-\dfrac{T_s}{R_1C_1}\right)U_1(lT_s) + \int_0^T \dfrac{I_l(lT_s)}{C_1}\mathrm{d}t \\ U_2[(l+1)T_s] = \\ \quad \exp\left(-\dfrac{T_s}{R_2C_2}\right)U_2(lT_s) + \int_0^T \dfrac{I_l(lT_s)}{C_2}\mathrm{d}t \end{cases} \tag{3}$$

在多时间尺度离散后，有

$$\begin{cases} U_{1,k,l} = \exp\left(\dfrac{T_s}{R_1C_1}\right)\cdot U_{1,k,l-1} + \\ \quad \left[1-\exp\left(\dfrac{T_s}{R_1C_1}\right)\right]R_1 I_{k,l} \\ U_{2,k,l} = \exp\left(\dfrac{T_s}{R_2C_2}\right)\cdot U_{2,k,l-1} + \\ \quad \left[1-\exp\left(\dfrac{T_s}{R_2C_2}\right)\right]R_2 I_{k,l} \end{cases} \tag{4}$$

令 $Z_k = Z_{k,l-1}$，由式(1)的第 3 个式子得到

$$Z_{k,l} = Z_{k,l-1} - \frac{\mu I_k T_s}{Q_n} \tag{5}$$

由状态方程式(1)得到

$$\begin{bmatrix} U_{1,k,l} \\ U_{2,k,l} \\ Z_{k,l} \end{bmatrix} = \begin{bmatrix} \exp\left(\dfrac{-T_s}{R_1C_1}\right) & 0 & 0 \\ 0 & \exp\left(\dfrac{-T_s}{R_2C_2}\right) & 0 \\ 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} U_{1,k,l-1} \\ U_{2,k,l-1} \\ Z_{k,l-1} \end{bmatrix} + \begin{bmatrix} 1-\exp\left(\dfrac{-T_s}{R_1C_1}\right)R_1 \\ 1-\exp\left(\dfrac{-T_s}{R_2C_2}\right)R_2 \\ \dfrac{-T_s}{Q_n} \end{bmatrix} \cdot \boldsymbol{I}_{k,l} \tag{6}$$

多时间尺度上的离散化状态方程和观测方程分别为

$$\boldsymbol{X}_{k,l+1} = \begin{bmatrix} \exp\left(\dfrac{-T_s}{R_1C_1}\right) & 0 & 0 \\ 0 & \exp\left(\dfrac{-T_s}{R_2C_2}\right) & 0 \\ 0 & 0 & 1 \end{bmatrix} \boldsymbol{X}_{k,l} + \begin{bmatrix} 1-\exp\left(\dfrac{-T_s}{R_1C_1}\right)R_1 \\ 1-\exp\left(\dfrac{-T_s}{R_2C_2}\right)R_2 \\ \dfrac{-\mu T_s}{Q_n} \end{bmatrix} \boldsymbol{u}_{k,l} \tag{7}$$

$$y_{k,l} = g_{z_{k,l}} - U_{1,k,l} - U_{2,k,l} - R_0 u_k \tag{8}$$

令 $\boldsymbol{\theta}_k = [R_0\ R_1\ C_1\ R_1\ R_2]_k^{\mathrm{T}}$；$\boldsymbol{X}_{k,j} = [U_{1,k,j}\ U_{2,k,j}\ Z_{k,j}]$。为进一步推广使用，将式(7)和式(8)改写为

$$\boldsymbol{X}_{k,l+1} = F(\boldsymbol{X}_{k,l}, \boldsymbol{u}_{k,l}, \boldsymbol{\theta}_k) + \omega_{k,l} \quad \boldsymbol{\theta}_{k+1} = \boldsymbol{\theta}_k + \boldsymbol{r}_k \tag{9}$$

$$\boldsymbol{y}_{k,l} = G(\boldsymbol{X}_{k,l}, \boldsymbol{u}_{k,l}, \boldsymbol{\theta}_k) + v_{k,l} \tag{10}$$

式中：$\omega_{k,l}$ 与 $v_{k,l}$ 分别为系统过程噪声与观测噪声；r_k 为模型参数的过程噪声。

2 基于 BP−多时间尺度 UKF 优化算法的 SOC 估计

2.1 BP−多时间尺度 UKF 优化算法

目前组合算法受制于模型精度与算法缺陷的影

响，导致滤波算法生成数据并不能准确反映电池特征，不仅需要大量数据弥补数据可靠性低的问题，而且估计效果也有限。为此，本文将多时间尺度理论运用到组合算法中，设计了一种 BP−多时间尺度 UKF 优化算法，使用多时间尺度 EKF 辨识参数，在一定程度上优化了模型精度，滤波算法得到的数据可充分反映电池特征，减少训练数据的同时也为下一步误差补偿提供了可靠数据，有效提高了算法的泛化能力与实用性。利用复杂映射能力的 BP 网络具有较强学习能力，可进行误差补偿最终达到优化算法目的。

图 2 为所提算法模型，其中左半部分为多时间尺度的 UKF-EKF 算法，右半部分利用 BP 误差补偿输出当前时刻的 SOC。本文规定：带有右上标“−”为先验值，带有上标“^”为估计值。具体算法为：第 1 步，时间更新参数 $\hat{\theta}_{k+1}^{-}$；第 2 步，时间更新状态变量 $\hat{X}_k^{-}$；第 3 步，测量更新变量 $\hat{X}_k$；第 4 步，测量更新参数 $\hat{\theta}_k^{-}$；第 5 步，滤波算法得到的初始 SOC 与 BP 输出进行误差补偿得到 k 时刻的 SOC。

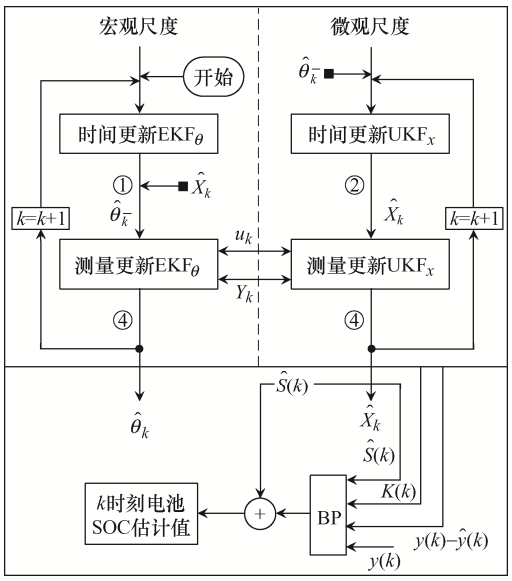


图 2 BP−多时间尺度 UKF 优化算法

Fig. 2 BP-multi-timescale UKF optimization algorithm

2.2 多时间尺度 UKF-EKF 算法

根据系统的多时间尺度离散化模型，考虑到建模的精度与电池管理系统 BMS(battery management system)的计算成本，决定在宏观尺度选用 EKF 辨识系统参数，在通过微观尺度选用 UKF 预测电池状态。多时间尺度算法通过宏观计算慢变量，通过微观计算快变量，有利于准确建模，进而准确估算电池状态。

图 3 为多时间尺度 UKF-EKF 算法框图，按照①~⑥次序依次计算。预测过程由宏观UKF与微观EKF以嵌套循环的形式执行。在宏观尺度下，每步 k 内 EKF 需依次进行时间更新、状态预测和测量更新。在微观尺度下，每步 l 内，UKF 需依次执行时间更新与测量更新。当微观尺度时间 l=L 时，说明此时的宏观时间步 k 结束，进行时间尺度变换，进入宏观时间步 k+1。需要值得注意的是，在微观与宏观时间尺度计算执行前，均需通过把基于先验信息的经验值赋予状态 X 和模型参数 θ 以进行初始化。

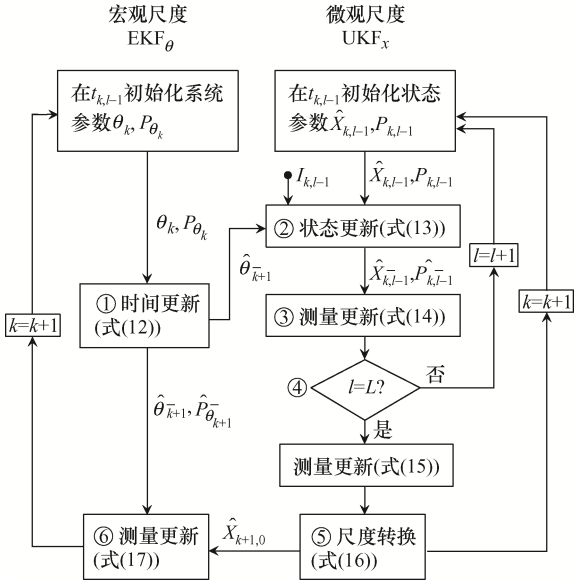


图 3 多时间尺度 UKF-EKF 算法框图

Fig. 3 Block diagram of multi-timescale UKF-EKF algorithm

具体算法步骤如下。

步骤 1 参数初始化。各参数初值表示为

$$\begin{cases} \boldsymbol{\theta}_0 = E[\boldsymbol{\theta}_0] \\ \boldsymbol{P}_{\theta_0} = E\left[(\boldsymbol{\theta}_0 - \hat{\boldsymbol{\theta}}_0)(\boldsymbol{\theta}_0 - \hat{\boldsymbol{\theta}}_0)^{\mathrm{T}}\right] \\ \boldsymbol{X}_{0,0} = E[\boldsymbol{X}_{0,0}] \\ \boldsymbol{P}_{X_{0,0}} = E\left[(\boldsymbol{X}_{0,0} - \hat{\boldsymbol{X}}_{0,0})(\boldsymbol{X}_{0,0} - \hat{\boldsymbol{X}}_{0,0})^{\mathrm{T}}\right] \end{cases} \tag{11}$$

式中：$\boldsymbol{P}_{\theta_0}$ 为参数状态误差协方差；$\boldsymbol{P}_{X_{0,0}}$ 为状态参数误差协方差。

步骤 2 宏观尺度下更新时间。参数更新为

$$\begin{cases}\hat{\boldsymbol{\theta}}_{k+1}^{-}=\hat{\boldsymbol{\theta}}_{k}\\ \hat{\boldsymbol{P}}_{\theta_k}^{-}=\boldsymbol{P}_{\theta_k}+\boldsymbol{P}_{\rho_k}\end{cases}\tag{12}$$

步骤 3　微观尺度下选择合适的 sigma 点预测状态值，则有

$$\begin{cases}\hat{\boldsymbol{X}}_{k,l}^{-}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\boldsymbol{X}_{k,l-1}^{(i)}\\ \hat{\boldsymbol{P}}_{X_{k,l-1}}^{-}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\left[\boldsymbol{X}_{k,l-1}^{(i)}-\hat{\boldsymbol{X}}_{k,l}^{-}\right]\left[\boldsymbol{X}_{k,l-1}^{(i)}-\hat{\boldsymbol{X}}_{k,l}^{-}\right]^{\mathrm{T}}+\\ \qquad\boldsymbol{P}_{W_{k,l-1}}\end{cases}\tag{13}$$

步骤 4　微观尺度下计算状态变量，即有

$$\begin{cases}\hat{\boldsymbol{Y}}_{X_{k,l-1}}^{-}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\boldsymbol{Y}_{k,l-1}^{(i)}\\ \boldsymbol{P}_{k,l}^{yy}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\left[\boldsymbol{Y}_{k,l-1}^{(i)}-\hat{\boldsymbol{Y}}_{k,l-1}^{-}\right]\left[\boldsymbol{Y}_{k,l-1}^{(i)}-\hat{\boldsymbol{Y}}_{k,l-1}^{-}\right]^{\mathrm{T}}+\boldsymbol{P}_{V_{k,l-1}}\\ \boldsymbol{P}_{k,l}^{xy}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\left[\boldsymbol{X}_{k,l-1}^{(i)}-\hat{\boldsymbol{X}}_{k,l-1}^{-}\right]\left[\boldsymbol{X}_{k,l-1}^{(i)}-\hat{\boldsymbol{X}}_{k,l-1}^{-}\right]^{\mathrm{T}}\\ \boldsymbol{K}_{k,l}=\boldsymbol{P}_{k,l}^{xy}\boldsymbol{P}_{k,l}^{yy}\\ \hat{\boldsymbol{X}}_{k,l}=\hat{\boldsymbol{X}}_{k,l}^{-}+\boldsymbol{K}_{k,l}\left[\boldsymbol{Y}_{k,l}(\boldsymbol{Y}_k-\hat{\boldsymbol{Y}}_{k,l-1})\right]\\ \boldsymbol{P}_{k,l}=\hat{\boldsymbol{P}}_{X_{k,l}}^{-}+\boldsymbol{K}_{k,l}\boldsymbol{P}_{k,l}^{yy}\boldsymbol{K}_{k,l}^{\mathrm{T}}\end{cases}\tag{14}$$

步骤 5　微观尺度下计算当 l=L 时的状态估计值，分别表示为

$$\begin{cases}\hat{\boldsymbol{Y}}_{k,L-1}^{-}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\boldsymbol{Y}_{k,l-1}^{(i)}\\ \boldsymbol{P}_{k,L-1}^{yy}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\left[\boldsymbol{Y}_{k,L-1}^{(i)}-\hat{\boldsymbol{Y}}_{k,L-1}^{-}\right]\left[\boldsymbol{Y}_{k,L-1}^{(i)}-\hat{\boldsymbol{Y}}_{k,L-1}^{-}\right]^{\mathrm{T}}+\boldsymbol{P}_{V_{k,l-1}}\\ \boldsymbol{P}_{k,L-1}^{xy}=\sum\limits_{i=0}^{2n}\boldsymbol{W}^{(i)}\left[\boldsymbol{X}_{k,L-1}^{(i)}-\hat{\boldsymbol{X}}_{k,L-1}^{-}\right]\left[\boldsymbol{X}_{k,L-1}^{(i)}-\hat{\boldsymbol{X}}_{k,L-1}^{-}\right]^{\mathrm{T}}\\ \boldsymbol{K}_{k,L}=\boldsymbol{P}_{k,L-1}^{xy}\boldsymbol{P}_{k,L-1}^{yy}\\ \hat{\boldsymbol{X}}_{k,L}=\hat{\boldsymbol{X}}_{k-1,L}^{-}+\boldsymbol{K}_{k,L}\left[\boldsymbol{K}_{k,L}(\boldsymbol{Y}_k-\hat{\boldsymbol{Y}}_{k,L-1})\right]\\ \boldsymbol{P}_{k,L}=\hat{\boldsymbol{P}}_{X_{k,L-1}}^{-}+\boldsymbol{K}_{k,L}\boldsymbol{P}_{k,L}^{yy}\boldsymbol{K}_{k,L}^{\mathrm{T}}\end{cases}\tag{15}$$

步骤 6　尺度转换，则有

$$\begin{cases}\hat{\boldsymbol{X}}_{k+1,0}=\hat{\boldsymbol{X}}_{k,L}\\ \boldsymbol{P}_{k+1,0}=\boldsymbol{P}_{k,L}\\ \hat{\boldsymbol{Y}}_{k+1,0}=\hat{\boldsymbol{Y}}_{k,L}\\ \boldsymbol{u}_{k+1,0}=\boldsymbol{u}_{k,L}\end{cases}\tag{16}$$

步骤 7　宏观尺度下测量更新，则有

$$\begin{cases}\boldsymbol{K}_{k+1}^{\theta}=\boldsymbol{P}_{\theta_{k+1}}^{-}(\boldsymbol{C}_{k+1}^{\theta})\left[\boldsymbol{C}_{k+1}^{\theta}\boldsymbol{P}_{\theta_{k+1}}^{-}(\boldsymbol{C}_{k+1}^{\theta})^{\mathrm{T}}+\boldsymbol{P}_{V_{k+1}}\right]\\ \hat{\boldsymbol{\theta}}_{k+1}=\hat{\boldsymbol{\theta}}_{k+1}^{-}+\boldsymbol{K}_{k+1}^{\theta}\left[\boldsymbol{Y}_{k+1,0}-G(\hat{\boldsymbol{X}}_{k+1,0},\hat{\boldsymbol{\theta}}_{k+1}^{-})\right]\\ \boldsymbol{P}_{\theta_{k+1}}=(\boldsymbol{I}-\boldsymbol{K}_{k+1}^{\theta}\boldsymbol{C}_{k+1}^{\theta})\boldsymbol{P}_{\theta_{k+1}}^{-}\end{cases}\tag{17}$$

雅克比矩阵为

$$\begin{cases}\boldsymbol{A}_{k,l-1}=\dfrac{\partial F(\boldsymbol{X},\hat{\boldsymbol{\theta}}_{k+1}^{-},\boldsymbol{u}_{k,l-1})}{\partial\boldsymbol{X}}\Big|_{\boldsymbol{X}=\hat{\boldsymbol{X}}_{k,l-1}}\\ \boldsymbol{C}_{k,l}^{X}=\dfrac{\partial G(\boldsymbol{X},\hat{\boldsymbol{\theta}}_{k+1}^{-},\boldsymbol{u}_{k,l})}{\partial X}\Big|_{\boldsymbol{X}=\hat{\boldsymbol{X}}_{k,l}^{-}}\\ \boldsymbol{C}_{k+1}^{\theta}=\dfrac{\mathrm{d}G(\hat{\boldsymbol{X}}_{k+1,0},\boldsymbol{\theta},\boldsymbol{u}_{k+1,0})}{\mathrm{d}\boldsymbol{\theta}}\Big|_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}_{k+1}^{-}}\end{cases}\tag{18}$$

2.3 BP 神经网络算法

BP 神经网络算法的工作过程由激励传播与权值更新两阶段组成。其中：在激励传播中，依次完成获得激励响应与响应误差的任务；在下一阶段完成权重更新。两阶段反复循环迭代，直至达到预期设定的目标范围内。

本文选用输入层神经元数为 4、隐含层为 10、输出层为 1 的 3 层网络结构，如图 4 所示，其中输入层、隐藏层、输出层分别由 L_{i}、L_{h}、L_{o} 表示，V_{ij}、W_{ij} 分别为上一层的第 i 个神经元到下一层的第 j 个神经元的传递权值。为对滤波算法输出值进行误差补偿，考虑到输入输出相关性，将端电压的真实值 $y(k)$、卡尔曼滤波增益 $K(k)$、滤波估计端电压误差 $y(k)-\hat{y}(k)$、滤波算法输出的 SOC 值 $\hat{S}(k)$ 作为神经网络输入，SOC 真实值与滤波后最优估计值之差 $S(k)-\hat{S}(k)$ 作为神经网络的输出。

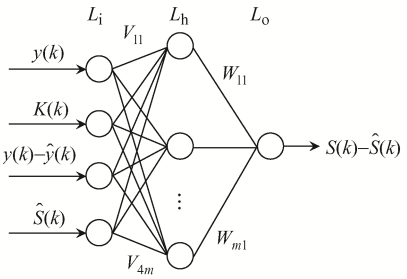


图 4　3 层 BP 神经网络

Fig. 4 Three-layer BP neural network

3 实验与结果分析

本节为充分展示所提算法的有效性，设计了2个对比实验，分别基于自采数据集与公开数据集进行，并与其他同类算法比较。在基于自采数据集下的对比实验中，模拟工况为城市道路循环UDDS (urban dynamometer driving schedule)工况，将数据集划分为7∶3的训练测试集，标定初始偏差为20%，分析本模型的有效性以及所提算法在估计精度、鲁棒性方面的性能。在基于公开数据集下的对比实验中，标定初始误差为10%，在DST(discharge-stop-reload)工况上训练，在FUDS(full urban driving schedule)、US06、BJDST数据集上进行测试，训练集与测试集比例为1∶1，以验证所提算法在估计精度、泛化能力、鲁棒性、对数据量依赖方面的性能。

本文规定，BP-EKF[14]与BP-EKF[15]分别为文献[14]、[15]所提的BP-EKF算法，MTS-UKF为多时间尺度UKF算法。

3.1 基于自采数据集下的对比实验

3.1.1 实验平台

为验证模型的准确性和所提算法对实际工况的估计效果，搭建如图5所示的实验平台。



图5 实验设备

Fig. 5 Experimental equipment

实验平台主要包括锂离子电池、充放电设备、恒温箱以及PC端。其中：锂离子电池选用一款型号18650的钴酸锂电池，具体参数见表1；充放电设备用于模拟电动汽车锂离子电池的实际运行工况；恒温箱为电池提供恒温环境；PC端采集锂离子电池放电数据。为尽可能模拟电动汽车的实际运行工况，本实验选用10节电池单体并联，并模拟UDDS工况从100%至20%的SOC，得到的电池电流变化情况如图6所示。

表1 所测电池的基本参数

Tab. 1 Basic parameters of tested batteries

参数	额定规格
直径/mm	18.33±0.07
长度/mm	64.85±0.15
质量(最大)/g	48.0
额定电压/V	3.6
内阻(AC 1 kHz)/mΩ	≤18
内阻(DC 1~10 A)/mΩ	≤30
额定容量/(mA·h)	3 000

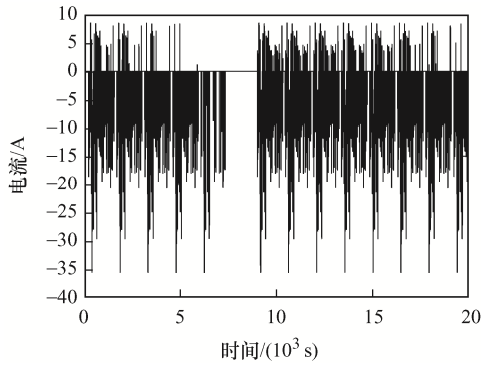


图6 UDDS工况电流

Fig. 6 Current under UDDS working condition

3.1.2 实验结果与分析

首先，在UDDS工况下利用多时间尺度UKF算法计算得到未误差补偿前的SOC、端电压误差和SOC估计误差。其中SOC估计误差曲线和端电压误差曲线分别如图7和图8所示，由图8可知由于SOC初值标定偏差，导致端电压初始误差很大，但是收敛后的电压最大误差小于0.05 V，验证了所建模型的有效性。由图7可知，当SOC初值标定偏差较大时，滤波算法的SOC估计误差可快速接近0，最大误差保持在0.02以内。

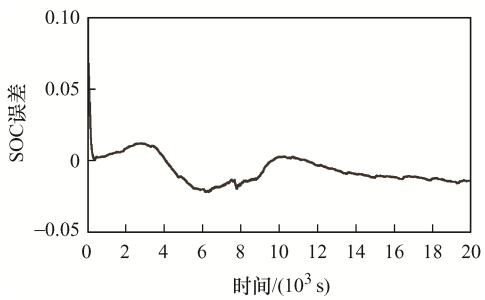


图7 SOC估计误差

Fig. 7 SOC estimation error

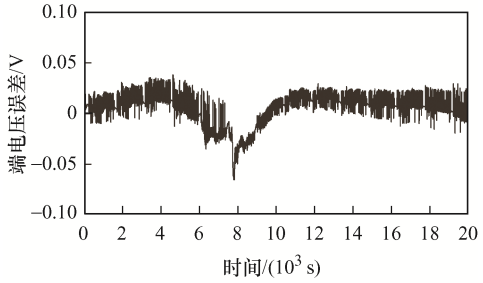


图 8　端电压误差

Fig. 8 Terminal voltage error

然后，对 BP 网络模型训练。设置训练迭代最大次数为 5 000，期望误差 10^{-4}，当置信度大于 0.99 时模型训练成功。选用多时间尺度 UKF-EKF 算法得到的 UDDS 工况的滤波数据训练 BP 模型，再将训练完成的 BP 网络与多时间尺度 UKF 组合进行 SOC 估计，得到的 SOC 误差曲线如图 9 所示。

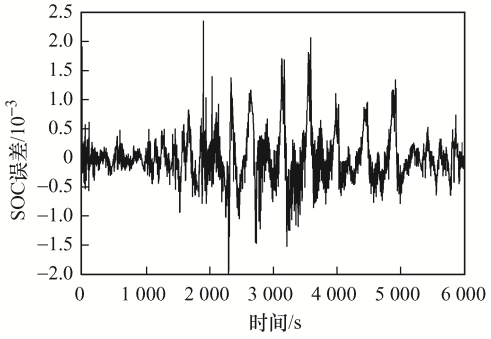


图 9　BP-UKF 的 SOC 误差值

Fig. 9 Error value of SOC for BP-UKF algorithm

由图 7 和图 9 比较可知，加入 BP 误差补偿后的 SOC 误差相比于 MTS-UKF 算法有明显改善，波动幅度更小，充分表明了所提算法具有较好的预测能力。所提算法与其他算法对比见表 2。由表 2 可知，当加入 BP 误差补偿后均方根误差 RMSE(root mean square error)、平均绝对误差 MAE(mean absolute error)、最大绝对误差 ME(maximum absolute error)分别由 1.11%、0.97%、2.20%降至 0.04%、0.02%、0.23%，有效提高了模型的估计精度与鲁棒能力。本文算法与 BP-EKF[14]相比较，RMSE、MAE、ME 分别降低了 69.23%、75.00%、79.65%，与 BP-EKF[15]相比较，RMSE、MAE、ME 分别降低了 63.64%、71.43%、85.16%，表明所提算法在估计精度、鲁棒性方面优于同类算法。

表 2　本文算法与其他算法对比

Tab. 2 Comparison of proposed algorithm with other algorithms

算法	RMSE/%	MAE/%	ME/%
BP-EKF[14]	0.13	0.08	1.13
BP-EKF[15]	0.11	0.07	1.55
MTS-UKF	1.11	0.97	2.20
本文算法	0.04	0.02	0.23

3.2 基于公开数据集下的对比实验

本次实验中，选取马里兰大学电池数据集中的 FUDS、US06、BJDST 作为测试工况，DST 模拟工况为训练工况，测试环境温度分别为 25 ℃与 45 ℃，训练集与测试集的比例为 1∶1，其余实验细节均与 3.1 节中相同。由于 BP 算法存在局部最优问题，故选取 10 次结果的平均值。

3.2.1　环境温度 25 ℃下测试分析

与同类的 2 种算法在相同的数据集上进行对比，得到图 10~图 12 的 3 种工况的 SOC 估计效果图。由图 10 与图 11 可见，在初始误差较大的情况下，对比算法在收敛后均出现较大波动，但本文算法未出现较大波动，展现出了很强的鲁棒能力。由图 12 可见，BP-EKF[15]起始波动较大，稳定后的一段时间内均保持较好估计精度，但后半段出现较大偏差；本文算法在稳定后波动小，整体精度更高，展现出明显优势。由图 10~图 12 可见，本文算法具有良好的预测能力、较高的预测精度和较强的鲁棒性。

3 种算法的估计误差见表 3。从 RMSE 角度分析，本文算法在 FUDS、US06、BJDST工况下结果

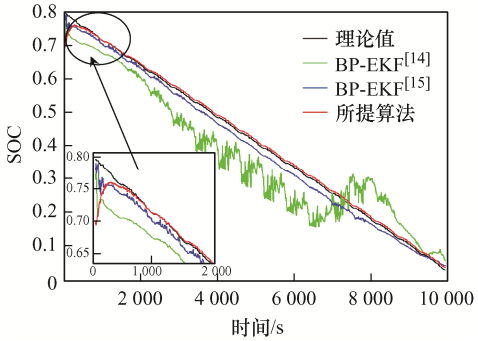


图 10　US06 数据验证结果

Fig. 10 Verification results based on US06 dataset

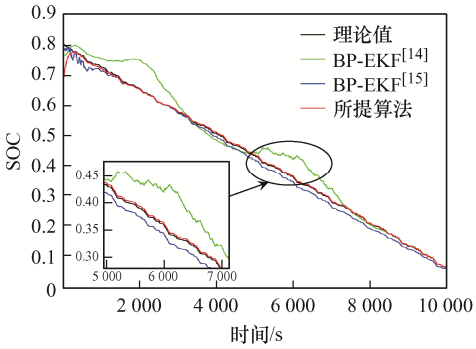


图 11 BJDST 数据验证结果

Fig. 11 Verification results based on BJDST dataset

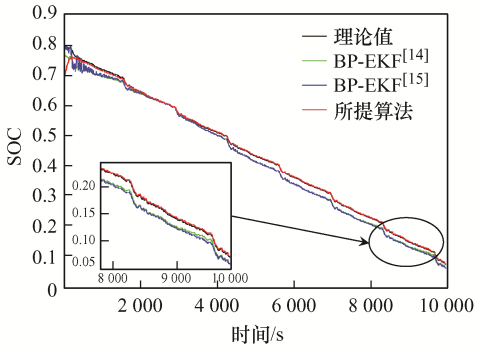


图 12 FUDS 数据验证结果

Fig. 12 Verification results based on FUDS dataset

表 3 3 种算法的估计误差

Tab. 3 Estimation errors of three algorithms

评价指标	FUDS 工况			US06 工况			BJDST 工况		
	BP-EKF[14]	BP-EKF[15]	本文算法	BP-EKF[14]	BP-EKF[15]	本文算法	BP-EKF[14]	BP-EKF[15]	本文算法
RMSE/%	3.25	1.73	0.28	7.98	1.80	0.60	5.25	1.32	0.30
MAE/%	2.51	1.56	0.24	7.08	1.66	0.57	4.06	1.17	0.27
ME/%	13.7	4.26	1.05	15.92	3.62	1.20	13.11	3.41	0.66

分别为 0.28%、0.60%、0.30%，与 BP-EKF[14]预测结果比较分别、降低了 91.38%、92.48%、94.29%，与 BP-EKF[15]预测结果比较分别降低了 83.82%、66.67%、77.27%。从 MAE 角度分析，所提算法在 FUDS、US06、BJDST 工况下结果为 0.24%、0.57%、0.27%，与 BP-EKF[14]预测结果比较分别降低了 90.44%、91.95%、93.35%，与 BP-EKF[15]预测结果比较分别降低了84.62%、65.66、76.92%。可见，本文算法的估计精度优于其他 2 种 BP-EKF 算法。从 ME 角度分析，本文算法可将误差有效降低到 1%左右，在 FUDS、US06、BJDST 工况下的估计误差相比于 BP-EKF[14]算法分别降低了 92.34%、92.46%、94.97%，相比于 BP-EKF[15]算法分别降低了 75.35%、66.85%、80.65%，表现出较强的鲁棒能力。在本实验中，本文算法在 3 种工况下均展现出优异的预测能力，充分表明该算法具有较强的泛化能力。

不同于传统的训练集与测试集比例 7∶3，在训练集与测试集比例为 1∶1 时本文算法仍能发挥良好的性能，可知本文算法在数据驱动部分对数据量的依赖小。

3.2.2 环境温度 45 ℃下测试分析

本文算法在测试环境 45 ℃下的预测误差见表 4。可知，在 3 种工况下 RMSE 分别为 0.42%、0.61%、0.63%，均小于 1.00%；MAE 分别为 0.30%、0.24%、0.49%，均小于 0.50%；ME 分别为 1.26%、1.46%、0.91%，接近常温下测试结果。由此可知，该算法在温度 45 ℃时仍具有良好的预测能力。由于算法分别在不同温度的 3 种工况下均展现出优异的预测能力，充分说明该算法具有优秀的泛化能力。

表 4 所提算法的估计误差(45 ℃)

Tab. 4 Estimation errors of proposed algorithm(45 ℃)

工况	RMSE/%	MAE/%	ME/%
FUDS	0.42	0.30	1.26
US06	0.61	0.24	1.46
BJDST	0.63	0.49	0.91

以上实验的结果表明，本文算法由于增加了多时间尺度理论建模，不仅一定程度上解决了因参数变化造成的 SOC 误差，而且使得滤波算法得到的数据更能反映电池特征，为下一步误差补偿提供了可靠数据的同时提高了算法泛化能力，还降低了数据驱动部分对数据量的依赖。合理选择 BP 输入数据，在弥补因建模精度而造成的误差同时有效抑制了噪声干扰，使得二次误差补偿在整体上有效地修正了误差，提高了估计精度和鲁棒能力。

4　结论

针对当前 SOC 估计的组合算法初值标定存在偏差，算法估计效果不理想的问题，本文提出了基于 BP−多时间尺度 UKF 优化组合算法，该算法具有以下优势：

(1)应用多时间尺度理论建模，使得 UKF 滤波的输出数据更精确地表征电池特性，有效提高了算法的泛化能力。

(2)多时间尺度 UKF 滤波的输出数据为训练 BP 网络提供了更可靠的数据，从而降低了 BP 网络训练对训练数据量的依赖性。

(3)选择合理的 BP 网络输入，提高了误差补偿效果，实现了SOC初值标定存在偏差时的高精度估计，均方根误差与平均绝对误差小于1%，最大绝对误差为1%左右，同时在整体泛化能力、鲁棒性方面均表现优异。

参考文献：

[1] 余运俊, 谌新, 万晓凤. 电动汽车电池荷电状态估计研究综述[J]. 电源学报, 2014, 12(3): 95-102.
Yu Yunjun, Chen Xin, Wan Xiaofeng. Reviewer of estimating the state of battery charge for electric vehicle [J]. Journal of Power Supply, 2014, 12(3): 95-102. (in Chinese)

[2] 邓哲, 黄震宇, 刘磊, 等. 超声技术在锂离子电池表征中的应用[J]. 储能科学与技术, 2019, 8(6): 1033-1039.
Deng Zhe, Huang Zhenyu, Liu Lei, et al. Applications of ultrasound technique in characterization of lithium-ion batteries [J]. Energy Storage Science and Technology, 2019, 8(6): 1033-1039. (in Chinese)

[3] 罗勇, 祁朋伟, 黄欢, 等. 基于容量修正的安时积分 SOC 估算方法研究[J]. 汽车工程, 2020, 42(5): 681-687.
Luo Yong, Qi Pengwei, Huang Huan, et al. Study on battery SOC estimation by ampere-hour integral method with capacity correction [J]. Automotive Engineering, 2020, 42(5): 681-687. (in Chinese)

[4] 李建林, 肖珩. 锂离子电池建模现状综述[J]. 储能科学与技术, 2022, 11(2): 697-703.
Li Jianlin, Xiao Heng. Review on modeling of lithium-ion battery [J]. Energy Storage Science and Technology, 2022, 11(2): 697-703. (in Chinese)

[5] Xu Zhicheng, Wang Jun, Fan Qi, et al. Improving the state of charge estimation of reused lithium-ion batteries by abating hysteresis using machine learning technique [J]. Journal of Energy Storage, 2020, 32: 101678.

[6] Ali O, Ishak M K, Ahmed A B, et al. On-line WSN SoC estimation using Gaussian process regression: an adaptive machine learning approach [J]. Alexandria Engineering Journal, 2022, 61(12): 9831-9848.

[7] Dai Haifeng, Xu Tianjiao, Zhu Letao, et al. Adaptive model parameter identification for large capacity Li-ion batteries on separated time scales [J]. Applied Energy, 2016, 184: 119-131.

[8] Xiong Rui, Sun Fengchun, Chen Zheng, et al. A data-driven multi-scale extended Kalman filtering based parameter and state estimation approach of lithium-ion polymer battery in electric vehicles [J]. Applied Energy, 2014, 113: 463-476.

[9] Wang Qiuxia, Wu Peizhou, Lian Jialing. SOC estimation algorithm of power lithium battery based on AFSA-BP neural network [J]. The Journal of Engineering, 2020, 2020(13): 535-539.

[10] Meng Jinhao, Luo Guangzhao, Gao Fei. Lithium polymer battery state-of-charge estimation based on adaptive unscented Kalman filter and support vector machine [J]. IEEE Transactions on Power Electronics, 2016, 31(3): 2226-2238.

[11] Shin D, Yoon B, Yoo S. Compensation method for estimating the state of charge of Li-polymer batteries using multiple long short-term memory networks based on the extended Kalman filter [J]. Energies, 2021, 14(2): 349.

[12] Zhou Wenlu, Zheng Yanping, Pan Zhengjun, et al. Review on the battery model and SOC estimation method [J]. Processes, 2021, 9(9): 1685.

[13] 孔祥创, 赵万忠, 王春燕. 基于 BP-EKF 算法的锂电池 SOC 联合估计[J]. 汽车工程, 2017, 39(6): 648-652.
Kong Xiangchuang, Zhao Wanzhong, Wang Chunyan. Co-estimation of lithium battery SOC based on BP-EKF

algorithm [J]. Automotive Engineering, 2017, 39(6): 648-652. (in Chinese)

[14] 徐艳民. 基于 BP-EKF 算法的电池 SOC 估计[J]. 汽车技术, 2018(2): 19-23.
Xu Yanmin. Estimation of SOC of battery based on BP-EKF algorithm [J]. Automobile Technology, 2018(2): 19-23. (in Chinese)

[15] 刘兴涛, 李坤, 武骥, 等. 基于 EKF-SVM 算法的动力电池SOC估计[J]. 汽车工程, 2020, 42(11): 1522-1528, 1544.
Liu Xingtao, Li Kun, Wu Ji, et al. State of charge estimation for traction battery based on EKF-SVM algorithm [J]. Automotive Engineering, 2020, 42(11): 1522-1528, 1544. (in Chinese)

[16] 李坤. 基于数据驱动与滤波算法融合的锂离子电池 SOC 估计方法研究[D]. 合肥: 合肥工业大学, 2021.
Li Kun. Research on SOC estimation method of lithium-ion battery based on data-driven and filtering algorithm fusion [D]. Hefei: Hefei University of Technology, 2021. (in Chinese)

[17] 贾先屹, 王顺利, 曹文, 等. 基于二阶 RC 等效电路和 SR-DUKF 算法的锂电池 SOC 估算研究[J]. 电源学报, 2024, 22(4): 236-242.
Jia Xianyi, Wang Shunli, Cao Wen, et al. Research on estimation of lithium battery SOC based on second-order RC equivalent circuit and SR-DUKF algorithm [J]. Journal of Power Supply, 2024, 22(4): 236-242. (in Chinese)

[18] 傅军栋, 陈浩杰, 孙翔, 等. 基于 EKF-Markov 的 UPS 荷电状态预测与健康管理系统[J]. 电源学报, 2024, 22 (6): 225-233.
Fu Jundong, Chen Haojie, Sun Xiang, et al. SOC prediction and health management system of UPS based on EKF-Markov [J]. Journal of Power Supply, 2024, 22(6): 225-233. (in Chinese)

[19] 贠祥, 张鑫, 王超, 等. 基于联合参数辨识的粒子群优化扩展粒子滤波的锂电池荷电状态估计[J]. 电工技术学报, 2024, 39(2): 595-606.
Yun Xiang, Zhang Xin, Wang Chao, et al. State of charge estimation of Li-ion battery using particle swarm optimization extended Kalman particle filter based on joint parameter identification[J]. Transactions of China Electrotechnical Society, 2024, 39(2): 595-606. (in Chinese)



白俊琦

作者简介：

白俊琦(1997—)，男，硕士研究生，中国电源学会会员。研究方向：锂电池荷电及健康状态预测。E-mail：junqibaiwy@163.com。

贤燕华(1978—)，女，通信作者，博士，讲师。研究方向：基于忆阻器的人工神经网络。E-mail：xyhua@mailbox.gxnu.edu.cn。

(责任编辑：陈国珍)