DOI：10.13234/j.issn.2095-2805.2026.9.155　　**中图分类号**：TM912　　**文献标志码**：A

基于动态广义相关熵优化 AEKF 的锂电池 SOC 估计

宋禹霆(中国电源学会学生会员)，周　俊
(昆明理工大学机电工程学院，昆明 650500)

摘要：针对非高斯噪声下传统扩展卡尔曼滤波 EKF(extended Kalman filter)荷电状态 SOC(state of charge)估计精度低和鲁棒性差的不足，提出基于动态广义最大相关熵准则优化的自适应扩展卡尔曼滤波 DGMCC-AEKF (dynamic generalized maximum correntropy criterion adaptive EKF)算法。该算法通过将广义最大相关熵准则替代卡尔曼滤波中的最小均方误差准则，提高了算法在非高斯噪声干扰下的鲁棒性，并提出一种基于指数形式结合迭代方法的动态调整核宽参数的策略，提高了算法的估计精度和稳定性。实验在动态压力测试 DST(dynamic stress test)和联邦城市驾驶工况 FUDS(federal urban driving schedule)下进行，在非高斯噪声干扰下新算法的平均绝对误差和均方根误差对比现有自适应扩展卡尔曼滤波 AEKF(adaptive EKF)、自适应迭代扩展卡尔曼滤波 AIEKF (adaptive iterated EKF)、最大相关熵准则扩展卡尔曼滤波 MCC-EKF(maximum correntropy criterion EKF)算法均降低，与其他自适应核宽方法在 4 种非高斯噪声方案下相比具有更好的估计性能。

关键词：锂离子电池；动态广义最大相关熵；扩展卡尔曼滤波；荷电状态估计

Lithium-ion Battery SOC Estimation Based on AEKF Optimized by Dynamic Generalized Correntropy

SONG Yuting, *Student Member, CPSS*, ZHOU Jun
(School of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Aiming at the shortcomings of low estimation accuracy and poor robustness of extended Kalman filter (EKF) state of charge (SOC) under non-Gaussian noise, an adaptive extended Kalman filter algorithm based on dynamic generalized maximum correntropy (DGMCC-AEKF) optimization is proposed. The algorithm improves the robustness by replacing the minimum mean square error criterion with the generalized maximum correntropy criterion, and proposes a strategy of dynamically adjusting the kernel width parameters based on the exponential form combined with the iterative method, which improves the accuracy and stability. Under dynamic stress test (DST) and federal urban driving schedule (FUDS) conditions, the mean absolute error and root mean squared error of the new algorithm are lower than those of the existing adapative extended Kalman filter (AEKF), adapative iterated extended Kalman filler (AIEKF) and maximum correntropy criterion extended Kalman filter (MCC-EKF) algorithms. Compared with other adaptive kernel width methods, it has better performance under four noise schemes.

Keywords: Lithium-ion battery; dynamic generalized maximum correntropy; extended Kalman filter (EKF); state of charge (SOC) estimation

随着新能源技术的广泛应用，为确保电池的安全使用及寿命的延长，需要依靠电池管理系统 BMS(battery management system)来精确调控并实时监测电池的各项参数及状态变化[1-2]。荷电状态 SOC(state of charge)作为衡量电池状态变化的核心指标之一，其精确估算在 BMS 中至关重要。然而因为锂电池内部化学反应的复杂性和时变性，直接

收稿日期：2024-12-31；**修回日期**：2025-02-16；**录用日期**：2025-03-02；**网络首发日期**：2025-03-14
基金项目：云南省基础研究计划面上项目(202301AT07 0439)
This work is supported by Basic Research Project of Yunnan Province under the grant 202301AT070439

测量 SOC 并不现实[3-4]。

目前的 SOC 估计方法已有许多种，模型法[5]因简单高效而获得了更多学者的重视。卡尔曼滤波作为模型法中的核心算法，其局限性在于不适用非线性模型[6]。为了克服这一限制，扩展卡尔曼滤波 EKF(extended Kalman filter)算法应运而生，通过高阶泰勒级数的展开，将 SOC 与开路电压之间的非线性关系进行线性化处理，从而实现近似计算[7]。文献[8]提出了利用重复迭代更新自适应扩展卡尔曼滤波 AEKF(adaptive extended Kalman filter)的自适应迭代扩展卡尔曼滤波 AIEKF(adaptive iterated EKF)的状态方程，使得算法能更快收敛至真实值。另有学者提出用最大相关熵准则取代卡尔曼滤波中的最小均方误差准则的最大相关熵准则扩展卡尔曼滤波 MCC-EKF(maximum correntropy criterion EKF)，显著提高了 EKF 的鲁棒性[9]。然而，此方法中最大相关熵准则对于核函数带宽的选择较为敏感，参数选择不当将会导致性能的降低，优化过程中难以收敛，使得算法难以稳定地找到全局最优解。文献[10]则在此基础上提出了一种根据残差和调节因子自适应调整核宽的自适应最大相关熵卡尔曼滤波方法，然而该方法中的调节因子需要人为校正，并且核宽的调整依赖于残差，若残差突变则核宽也发生突变，影响模型的稳定性。

针对现有算法的不足，本文提出了利用动态广义最大相关熵准则优化自适应扩展卡尔曼滤波 DGMCC-AEKF(dynamic generalized maximum correntropy criterion AEKF)的方法。该方法选用广义高斯核密度函数作为核函数，并提出了一种指数形式的自适应核宽动态调整策略，同时引入迭代机制以快速找到合适核宽，最后结合 AEKF 进行估计。实验表明，与 AEKF、AIEKF 和 MCC-EKF 3 种算法相比，本文所提算法在 SOC 估计中展现出了更好的估计性能。此外，通过与其他核宽自适应方法在 4 种非高斯噪声方案下的对比，进一步验证了 DGMCC-AEKF 的优越性。

1 电池模型与参数辨识

1.1 电池模型

对电池进行建模时，需要建立外部测量数据与电池内部状态之间的联系。电池的等效电路模型通过组合基本的电路元件来模拟电池特性，从而有效地捕捉电池工作时的实际状态。在评估了准确性需求和模型的复杂性后，本文选择二阶 RC 等效模型作为研究的起点，模型结构[11]如图 1 所示。图中：$U_{\mathrm{OCV}}(k)$ 为 k 时刻的电池开路电压；R_0 为电池的欧姆内阻；R_{p}、C_{p} 分别为电荷转移电阻和转移电容；R_{s}、C_{s} 分别为电池的扩散电阻和扩散电容；$U(k)$ 为模型输出端电压；I 为当前电流。

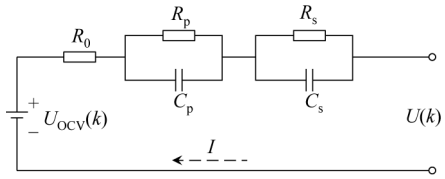


图 1 二阶 RC 等效模型结构

Fig. 1 Structure of second-order RC equivalent model

根据二阶 RC 等效电路模型，可以得到系统的状态空间方程为

$$\begin{bmatrix}\delta_{\mathrm{SOC}}(k)\\ U_{\mathrm{p}}(k)\\ U_{\mathrm{s}}(k)\end{bmatrix}=\begin{bmatrix}1 & 0 & 0\\ 0 & \mathrm{e}^{-\frac{\Delta k}{\tau_{\mathrm{p}}}} & 0\\ 0 & 0 & \mathrm{e}^{-\frac{\Delta k}{\tau_{\mathrm{s}}}}\end{bmatrix}\begin{bmatrix}\delta_{\mathrm{SOC}}(k-1)\\ U_{\mathrm{p}}(k-1)\\ U_{\mathrm{s}}(k-1)\end{bmatrix}+\begin{bmatrix}-\frac{\Delta k}{c}\\ R_{\mathrm{p}}(1-\mathrm{e}^{-\frac{\Delta k}{\tau_{\mathrm{p}}}})\\ R_{\mathrm{s}}(1-\mathrm{e}^{-\frac{\Delta k}{\tau_{\mathrm{s}}}})\end{bmatrix}I_{k-1} \tag{1}$$

式中：$\delta_{\mathrm{SOC}}(k)$ 为 k 时刻的荷电状态，k 为采样时间；U_{p}、U_{s} 分别为转移电压和扩散电压；Δk 为采样时间间隔；τ_{p}、τ_{s} 为时间常数，$\tau_{\mathrm{p}}=R_{\mathrm{p}}C_{\mathrm{p}}$，$\tau_{\mathrm{s}}=R_{\mathrm{s}}C_{\mathrm{s}}$；$c$ 为电池最大可用容量与库伦效率之比。

电池模型端电压预测方程为

$$y_k=U_{\mathrm{OCV}}(k)-U_{\mathrm{p}}(k)-U_{\mathrm{s}}(k)-R_0I_k \tag{2}$$

式中，y_k 为 k 时刻电池模型的端电压。

1.2 实验平台搭建

本文采用深圳市新威尔电子有限公司型号为 CTE-8008-5V300A 的电池测试设备，选用深圳市德力普电池科技有限公司型号为 18650 的锂电池单体为实验对象，并用恒温箱提供稳定的工作环

境。图 2(a)和图 2(b)分别为动态压力测试 DST (dynamic stress test)和联邦城市驾驶工况 FUDS (federal urban driving schedule)的测试电压和电流。实验数据由图 3 所示的实验平台测得。

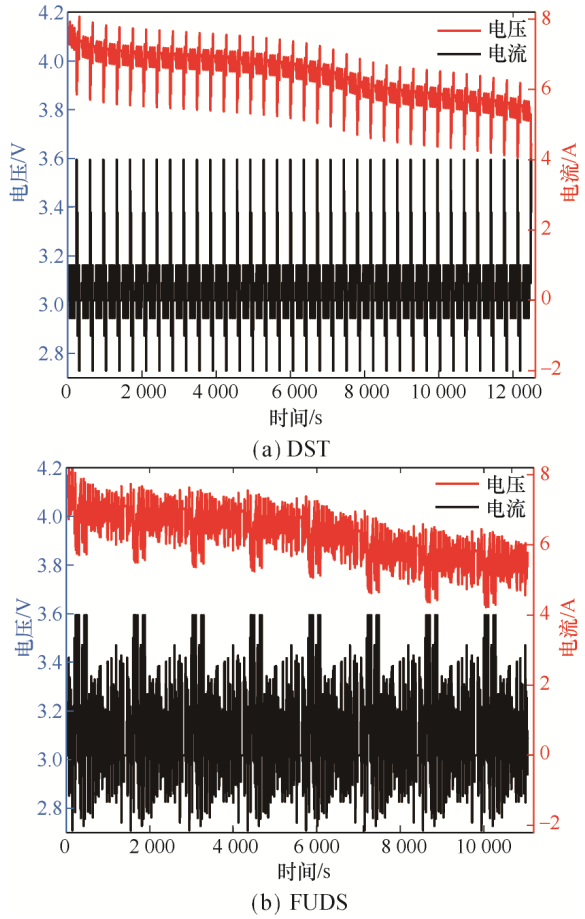


图 2　测试工况

Fig. 2 Test conditions



图 3　实验平台

Fig. 3 Experimental platform

1.3　参数辨识

在对 SOC 进行估计前，需要对电池模型的未知参数进行辨识。首先通过电池的充放电实验得到不同状态 SOC 对应的端电压，然后通过 MATLAB 的曲线拟合进行多项式拟合，得到 U_{OCV}-δ_{SOC} (SOC的值) 的关系曲线，其 7 阶拟合方程为

$$\begin{aligned} U_{OCV} = &-0.011\,2\times\delta_{SOC}^{7} - 0.003\,6\times\delta_{SOC}^{6} + \\ &0.055\,1\times\delta_{SOC}^{5} + 0.018\,7\times\delta_{SOC}^{4} - \\ &0.064\,2\times\delta_{SOC}^{3} - 0.031\,3\times\delta_{SOC}^{2} + \\ &0.088\,9\times\delta_{SOC} + 4.018\,9 \end{aligned} \tag{3}$$

图 4 为遗忘因子取 0.995、辨识工况为 DST 时的递推最小二乘法参数辨识结果。将辨识的参数结果代入式(1)和式(2)，可得预测的端电压。由于较多文献已对此方法的参数辨识过程和仿真验证进行了详细描述[12]，故本文不再赘述。

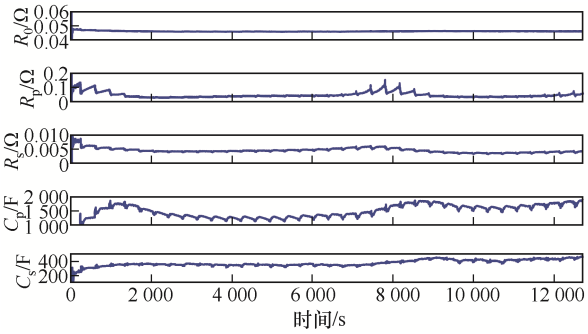


图 4　参数辨识结果

Fig. 4 Results of parameter identification

2　DGMCC-AEKF 算法流程

2.1　广义最大相关熵原理

最大相关熵准则在约束条件下实现最大化熵值，以优化输入与输出的关系，有效抑制了拖尾特性及脉冲噪声；而广义最大相关熵则增强了对多种分布非高斯噪声的适应性，在内核宽带较小时鲁棒性更强，且通过多参数设置比高斯核函数更灵活。对于 2 个变量 X、Y 的广义相似度 V_σ，可以定义为

$$V_\sigma(X,Y) = E[G_\sigma(X,Y)] = \iint G_\sigma(x,y)\mathrm{d}F_{X,Y}(x,y) \tag{4}$$

式中：E 为期望；x、y 为随机变量；$G_\sigma(x,y)$ 为

高斯核函数；$F_{X,Y}(x,y)$ 为 X、Y 的联合分布函数。

通过从参数集合中学习，得到最优参数 $\hat{W}$，使得相关熵获得最大值，即

$$\hat{W}=\mathrm{argmax}_W\frac{1}{N}\sum_{j=1}^{N}G_\sigma(u_j) \tag{5}$$

式中：$\boldsymbol{W}$ 为系统中需要求解的参数向量；N 为变量的样本数；u_j 为残差，$u_j=x_j-y_j$。u_j 与 $\boldsymbol{W}$ 之间存在映射 $u_j=f(\boldsymbol{W})$

广义最大相关熵准则采用了广义高斯核密度函数作为核函数[13]，其计算公式为

$$G_{\varepsilon,\sigma}(u_j)=\exp\left(-\frac{|u_j|^{\varepsilon}}{\sigma}\right) \tag{6}$$

式中：ε、σ 分别为 $G_{\varepsilon,\sigma}(u_j)$ 的形状参数与核宽，$\varepsilon>0$，$\sigma>0$，σ 可控制 $G_{\varepsilon,\sigma}(u_j)$ 的径向作用范围。

因此广义最大相关熵的损失函数 J_{MCC} 可以写为

$$J_{\mathrm{MCC}}=\frac{1}{N}\sum_{j=1}^{N}G_{\varepsilon,\sigma}(u_j) \tag{7}$$

2.2 DGMCC-AEKF 算法的步骤

AEKF 算法在高斯噪声假设条件下展现出良好的估计精度，但面对非高斯噪声时表现不佳。然而，通过引入最大相关熵准则，可以改善该环境下的估计精度。对于 MCC-AEK 算法，核宽的选择将会直接影响到算法对电池 SOC 估计的准确性，因此本文提出了 DGMCC-AEKF 算法，在引入了广义最大相关熵准则提高算法灵活性的同时，提出了一种基于指数形式的动态调整核宽的方法，以提高算法的估计精度和鲁棒性。DGMCC-AEKF 算法的计算过程如下。

锂电池的非线性系统[14]可以描述为

$$\begin{cases}\hat{x}_{k|k-1}=\boldsymbol{f}(x_{k-1})+\boldsymbol{Q}_{k-1}\\ \hat{y}_k=h(x_{k-1})+\boldsymbol{R}_{k-1}\end{cases} \tag{8}$$

式中：$\boldsymbol{f}(\cdot)$ 为状态转移矩阵；$h(\cdot)$ 为观测函数；$\boldsymbol{Q}_{k-1}$ 为过程噪声矩阵；$\boldsymbol{R}_{k-1}$ 为测量噪声矩阵。

构建系统状态表达式为

$$\begin{bmatrix}\hat{x}_{k|k-1}\\ \hat{y}_k\end{bmatrix}=\begin{bmatrix}\boldsymbol{I}\\ \boldsymbol{H}_k\end{bmatrix}x_{k-1}+\boldsymbol{\alpha}_k \tag{9}$$

式中：$\boldsymbol{I}$ 为单位矩阵；$\boldsymbol{H}_k$ 为 $h(\cdot)$ 的雅可比矩阵；$\boldsymbol{\alpha}_k$ 为误差协方差矩阵。

则误差协方差表达式为

$$\begin{aligned}E\left[\boldsymbol{\alpha}_k\boldsymbol{\alpha}_k^{\mathrm{T}}\right]&=\begin{bmatrix}\boldsymbol{P}_{k|k-1}&0\\0&\boldsymbol{R}_k\end{bmatrix}=\\&\begin{bmatrix}\boldsymbol{B}_{p,k|k-1}\boldsymbol{B}_{p,k|k-1}^{\mathrm{T}}&0\\0&\boldsymbol{B}_R\boldsymbol{B}_R^{\mathrm{T}}\end{bmatrix}\cdot\\&\begin{bmatrix}\boldsymbol{B}_{p,k|k-1}\boldsymbol{B}_{p,k|k-1}^{\mathrm{T}}&0\\0&\boldsymbol{B}_R\boldsymbol{B}_R^{\mathrm{T}}\end{bmatrix}^{\mathrm{T}}=\boldsymbol{B}_k\boldsymbol{B}_k^{\mathrm{T}}\end{aligned} \tag{10}$$

式中：$\boldsymbol{B}_p$、$\boldsymbol{B}_R$ 分别为由先验误差协方差矩阵 $\boldsymbol{P}_{k|k-1}$ 和测量误差协方差矩阵 $\boldsymbol{R}_k$ 进行 Cholesky 分解得到；$\boldsymbol{B}_k=\begin{bmatrix}\boldsymbol{B}_{p,k|k-1}\boldsymbol{B}_{p,k|k-1}^{\mathrm{T}}&0\\0&\boldsymbol{B}_R\boldsymbol{B}_R^{\mathrm{T}}\end{bmatrix}$。在式(9)两边同乘 $\boldsymbol{B}_k^{-1}$ 进而得到

$$\boldsymbol{L}_k=\boldsymbol{\Gamma}_k x_{k-1}+\boldsymbol{z}_k \tag{11}$$

式中：$\boldsymbol{L}_k=\boldsymbol{B}_k^{-1}[\hat{x}_{k|k-1}\ \ \hat{y}_k]^{\mathrm{T}}$；$\boldsymbol{\Gamma}_k=\boldsymbol{B}_k^{-1}[\boldsymbol{I}\ \ \boldsymbol{H}_k]^{\mathrm{T}}$；$\boldsymbol{z}_k=\boldsymbol{L}_k-\boldsymbol{\Gamma}_k x_{k-1}$。

引入广义最大相关熵准则构建代价函数为

$$J_{\mathrm{MCC}}(x_k)=\frac{1}{N}\sum_{i=1}^{N}G_{\varepsilon,\sigma}(\boldsymbol{z}_{k,i}) \tag{12}$$

定义权重矩阵为

$$\boldsymbol{C}_k=\begin{bmatrix}\boldsymbol{C}_{p,k}&0\\0&\boldsymbol{C}_{R,k}\end{bmatrix} \tag{13}$$

式中：$\boldsymbol{C}_{p,k}$ 为误差协方差权重矩阵，$\boldsymbol{C}_{p,k}=\mathrm{diag}(G_{\varepsilon,\sigma}(\boldsymbol{z}_{k,1}),\cdots,G_{\varepsilon,\sigma}(\boldsymbol{z}_{k,m}))$；$\boldsymbol{C}_{R,k}$ 为测量误差权重矩阵，$\boldsymbol{C}_{R,k}=\mathrm{diag}(G_{\varepsilon,\sigma})\boldsymbol{C}_{R,k}=\mathrm{diag}(G_{\varepsilon,\sigma}(\boldsymbol{z}_{k,m+1}),\cdots,G_{\varepsilon,\sigma}(\boldsymbol{z}_{k,n}))$。

修改后的误差协方差矩阵 $\hat{\boldsymbol{P}}_{k|k-1}$ 和测量噪声矩阵 $\hat{\boldsymbol{R}}_k$ 为

$$\hat{\boldsymbol{P}}_{k|k-1}=\boldsymbol{B}_{p,k|k-1}\boldsymbol{C}_{p,k}^{-1}\boldsymbol{B}_{p,k|k-1}^{\mathrm{T}} \tag{14}$$

$$\hat{\boldsymbol{R}}_k=\boldsymbol{B}_R\boldsymbol{C}_{p,k}^{-1}\boldsymbol{B}_R^{\mathrm{T}} \tag{15}$$

滤波增益矩阵 $\boldsymbol{K}_k$ 为

$$\boldsymbol{K}_k=\hat{\boldsymbol{P}}_{k|k-1}\boldsymbol{H}_k^{\mathrm{T}}(\boldsymbol{H}_k\hat{\boldsymbol{P}}_{k|k-1}\boldsymbol{H}_k^{\mathrm{T}}+\hat{\boldsymbol{R}}_k)^{-1} \tag{16}$$

后验估计 $\hat{x}_k$ 和后验误差协方差矩阵 $\boldsymbol{P}_k$ 更新为

$$\hat{x}_k=\hat{x}_{k|k-1}+\boldsymbol{K}_k(y_k-\hat{y}_k) \tag{17}$$

$$\boldsymbol{P}_k=\hat{\boldsymbol{P}}_{k|k-1}-\boldsymbol{K}_k\hat{\boldsymbol{P}}_{k|k-1}\boldsymbol{K}_k^{\mathrm{T}} \tag{18}$$

引入 Sage-Husa 自适应卡尔曼滤波算法[15]更新过程噪声矩阵为

$$\boldsymbol{\phi}_k = y_k - \hat{y}_k \tag{19}$$

$$\boldsymbol{Q}_k = (1-dk)\boldsymbol{Q}_{k-1} + dk(\boldsymbol{K}_k\boldsymbol{\phi}_k\boldsymbol{\phi}_k^{\mathrm{T}}\boldsymbol{K}_k^{\mathrm{T}}) \tag{20}$$

$$dk = \frac{1-b}{1-b^k} \tag{21}$$

式中：$\boldsymbol{\phi}_k$ 为预测误差矩阵；dk 为调节因子，由设定的遗忘因子 b 算出。

对于核宽 $\sigma_{i+1,k}$ 的选择，本文提出的动态调整公式为

$$\sigma_{i+1,k} = \sigma_{ik} \cdot \exp\left[1/\sqrt{1+\frac{\phi_k^3}{\sigma_{i,k}^3}} - 1\right] \tag{22}$$

式中：i 为判定公式的迭代次数；ϕ_k 为式(19)得到的误差，迭代过程判断式为

$$\frac{\left\|\hat{x}_{i,k} - \hat{x}_{i-1,k}\right\|}{\left\|\hat{x}_{i-1,k}\right\|} \leqslant \Delta \tag{23}$$

式中，Δ 为设定的阈值。若满足迭代判断，则跳出循环，否则回到式(12)重新计算广义最大相关熵，直至达到设定的迭代次数 n。DGMCC-AEKF 算法流程如图 5 所示。

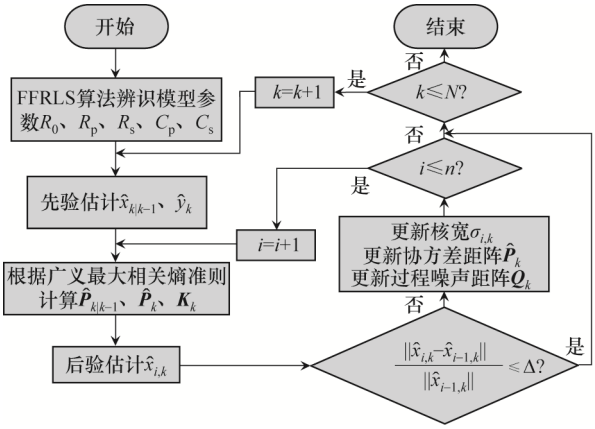


图 5　DGMCC-AEKF 算法流程

Fig. 5 Flow chart of DGMCC-AEKF algorithm

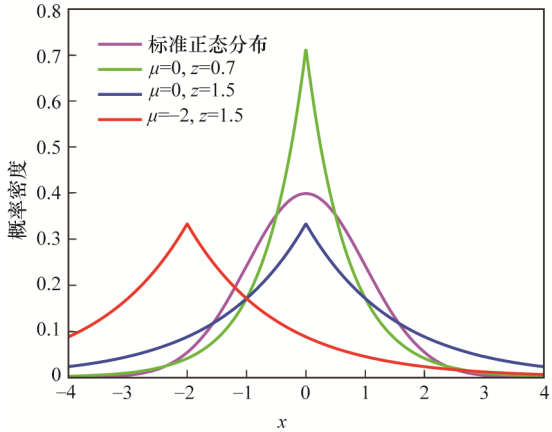
3　实验验证

采用 DST 和 FUDS 2 种工况进行验证，用所提算法与 AEKF、AIEKF 和 MCC-EKF 算法进行对比，重要的参数设置为：$\sigma = 8$，$b = 0.95$，$\varepsilon = 4$，$n = 20$，收敛阈值 $\Delta = 0.01$。

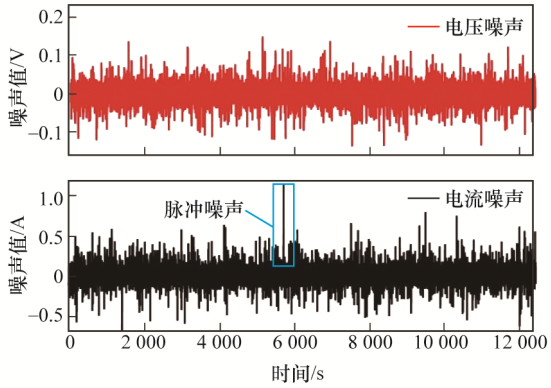
3.1　非高斯噪声下 SOC 估计

在电池的实际应用过程中，一般伴随着非高斯噪声的干扰。非高斯噪声指概率密度函数不满足高斯分布(即正态分布)的噪声，在实际应用中较为常见的非高斯噪声特性有重尾特性、脉冲特性和非对称特性等。重尾特性指因含有突发性的脉冲噪声，故其噪声分布在尾部区域比高斯分布具有更严重的重尾效应；脉冲特性指脉冲噪声持续时间短、振幅大，在实际应用中一般由外部电磁场的干扰、通信线路中的接触不良和电子设备的频繁启停等产生；非对称特性则指噪声分布不对称，一般由信号传输过程中的非线性失真、电力系统的负载变化等产生。因此，为探究算法的鲁棒性，本文在测量电压和电流中加入了拉普拉斯分布的噪声，通过调整位置参数 μ 和尺度参数 z 来模拟非高斯噪声，如图 6(a)所示。图 6(b)为电压和电流中加入的尺度参数分别为 0.02 和 0.10 的非高斯噪声。

图 7 为各算法在图 6(b)噪声干扰下的估计性能指标直方图，所提算法的均方根误差 RMSE(root mean squared error)和平均绝对误差 MAE(mean absolute error)最小，对比估计精度较高的 MCC-EKF 算法，DST 工况下 RMSE 降低 23.53%，MAE 降低 30.92%；FUDS 工况下 RMSE 降低 45.42%，MAE 降低 50.67%。图 8(a)和(b)分别为 DST 工况和 FUDS 工况的 SOC 估计，设置 SOC 初值为 0.95，由图可知，在初值不准确时，所提算法在第 4 s 时能够



(a) 拉普拉斯分布



(b) 非高斯噪声

图 6 非高斯噪声及分布

Fig. 6 Distribution of non-Gaussian noise

快速收敛。图 8(c)和(d)分别为 2 种工况的估计误差，因为选用了较为平稳的 4 000 s 时的电阻和电容作为模型参数，所以在后期面对电池的剧烈变化产生了较大误差。从图中可看出依靠测量值迭代调整的 AIEKF 在初值不准确及非高斯噪声干扰下估计能力不佳，而所提算法的估计精度要高于其他 3 种算法。

3.2 不同噪声下核宽变化的影响

在 MCC-EKF 算法中，核宽的选择影响着核函

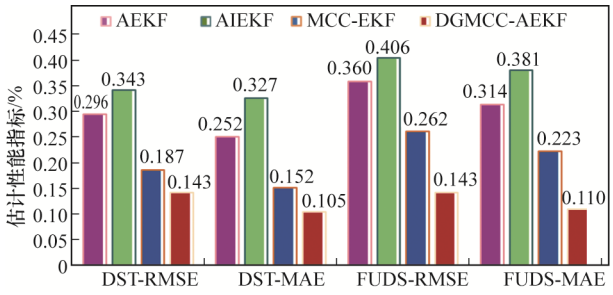
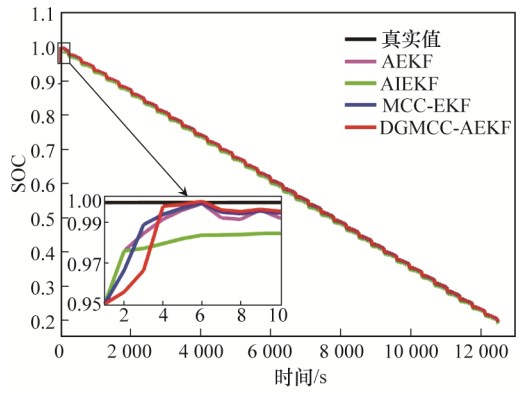
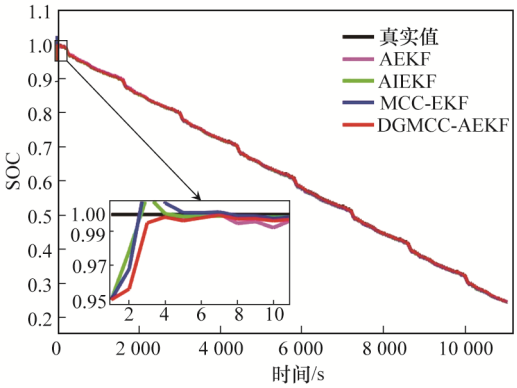


图 7 4 种算法的估计性能指标

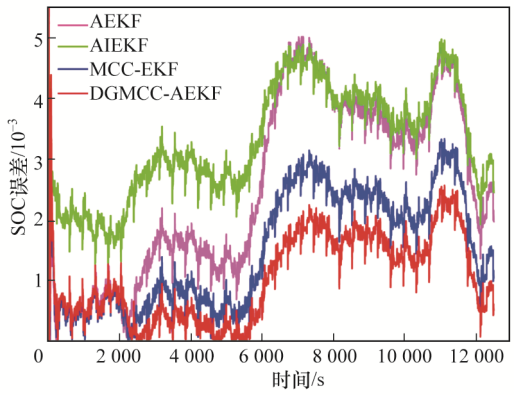
Fig. 7 Estimation performance indices of four algorithms



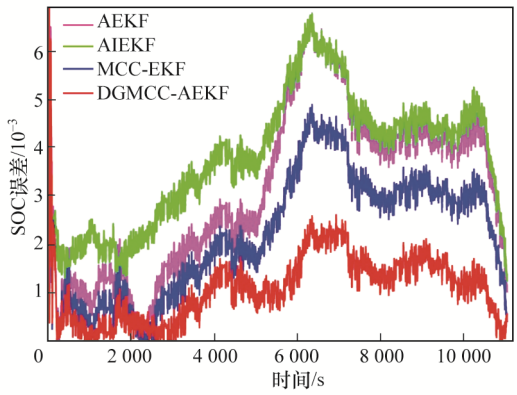
(a) DST工况SOC估计



(b) FUDS工况SOC估计



(c) DST工况SOC估计误差



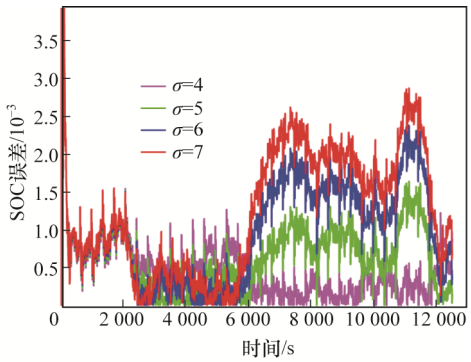
(d) FUDS工况SOC估计误差

图 8 SOC 估计及误差

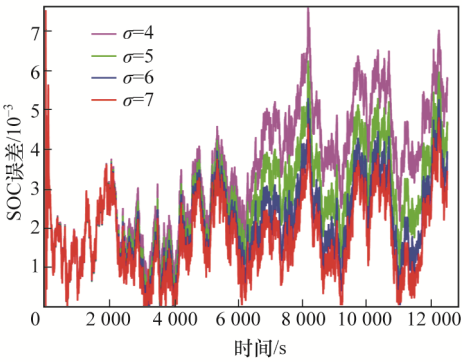
Fig. 8 SOC estimation and error

数的形状和范围，进而决定了相关熵对输入数据的敏感性和鲁棒性。较小的核宽收敛慢，对输入数据的微小变化更敏感，更有助于捕捉数据中的细节信息，同时也会导致模型对噪声和异常值过于敏感，降低了模型的鲁棒性；反之，较大的核宽有助于平滑数据中的噪声和异常值，提高了模型的鲁棒性，但也可能导致模型忽略重要的细节信息，因此核宽的选择严重影响着算法的估计性能。本节探讨了不

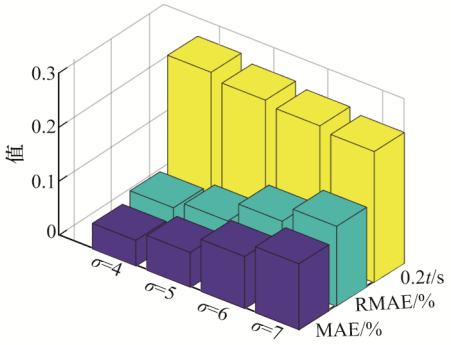
同噪声尺度下不同核宽的影响，选用的非高斯噪声与图 6(b)一致，只改变加入电流中的 z，选用了 4 种核宽 $\sigma=4$、$\sigma=5$、$\sigma=6$ 和 $\sigma=7$ 进行研究。图 9 为不同噪声尺度的估计误差及性能指标，图 9(a)和(b)为 DST 工况下噪声尺度分别为 0.1 和 0.5 时 4 种核宽的估计误差，图 9(c)和(d)分别为 4 种核宽在 2 种噪声下的估计性能三维柱状图。由三维柱状图可以看出，随着核宽的增大，估计的时间逐渐减少，此外，在噪声较小时，$\sigma=4$ 的估计精度最好，但是当噪声变大时，$\sigma=7$ 的估计精度反而更高。因此，面对实际工况中的噪声变化，需要动态调整 σ 以减弱噪声的影响。



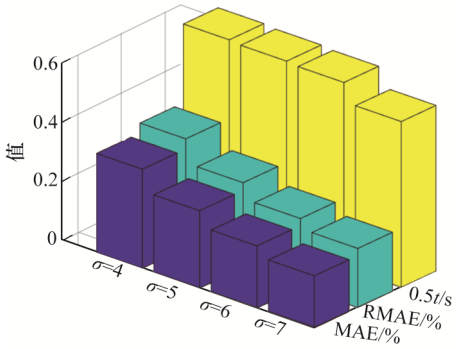
(a)尺度0.1时的误差



(b)尺度0.5时的误差



(c)尺度0.1时的性能指标



(d)尺度0.5时的性能指标

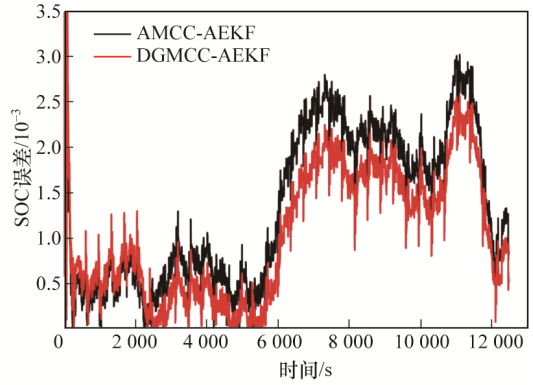
图 9　不同噪声尺度的估计误差及性能指标

Fig. 9 Estimation error and performance index of different noise scales

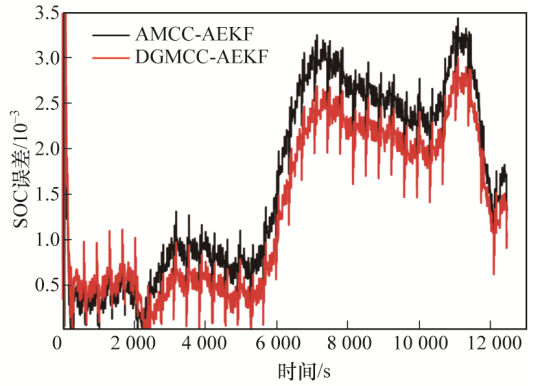
3.3　不同自适应方法的对比

目前已有许多文献提出了调整核宽的自适应算法，然而这些算法的缺点是主要依赖残差来调节核宽，对于残差的数值比较敏感，当残差出现微小变化时，可能引起核宽发生显著变化，降低估计的准确性，如文献[16]提出的自适应公式，根据残差及人为设定的调节因子调整核宽，面对复杂多变的工况无法找到一个合适的值去适应非高斯噪声。本文提出的自适应算法式(22)中采用 3 次方的形式降低了残差的波动程度，但保留了波动信息，然后利用指数的敏感性配合迭代方法快速找到合适的核宽，并且不需要人为设定调节因子，对于不同的噪声具有更好的适应性。

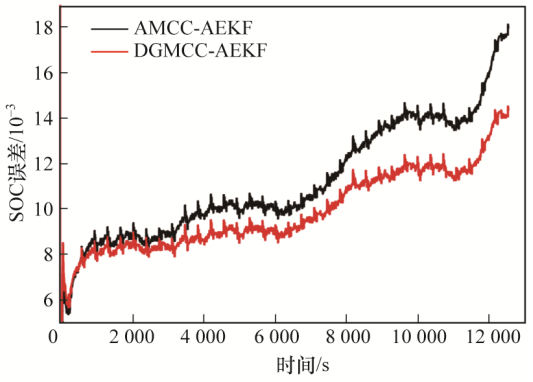
为对比 2 种方法的估计性能，本文设置了 4 种非高斯噪声方案，设定加入测量电压的噪声位置参数为 μ_1，尺度参数为 z_1；加入测量电流的噪声位置参数为 μ_2，尺度参数为 z_2。因此，设置方案 1：μ_1=0，z_1=0.02，μ_2=0，z_2=0.10；方案 2：μ_1=0，z_1=0.02，μ_2=0，z_2=0.05；方案 3：μ_1=0.02，z_1=0.02，μ_2=0，z_1=0.10；方案 4：μ_1=0，z_1=0.02，μ_2=0.01，z_2=0.10。图 10 为 2 种方法在 4 种噪声方案下的 DST 工况估计误差，AMCC-AEKF 采用了文献[16]提出的自适应方法，DGMCC-AEKF 为本文提出的动态调整方法。从图中可看出，面对不同的非高斯噪声，所提算法的鲁棒性和估计精度优于文献[16]提出的方法。表 1 列举了 2 种算法在 4 种方案下的估计精度指标，所提算法在方案 1 下，



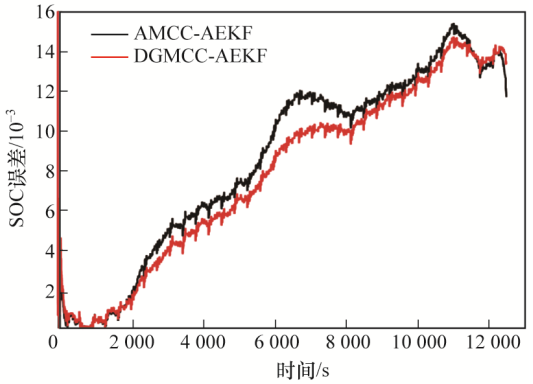
(a) 方案1



(b) 方案2



(c) 方案3



(d) 方案4

图 10 不同噪声方案的估计误差

Fig. 10 Estimation errors of different noise schemes

RMSE 降低 14.37%，MAE 降低 21.05%；在方案 2 下，RMSE 降低 13.07%，MAE 降低 18.40%；在方案 3 下，RMSE 降低 12.62%，MAE 降低 11.64%；在方案 4 下，RMSE 降低 6.43%，MAE 降低 7.61%。由此可看出，所提算法具有更优的估计性能。

表 1 估计精度指标

Tab. 1 Index of estimation accuracy

噪声方案	方法	RMSE/%	MAE/%
方案 1	AMCC-AEKF	0.167	0.133
	DGMCC-AEKF	0.143	0.105
方案 2	AMCC-AEKF	0.199	0.163
	DGMCC-AEKF	0.173	0.133
方案 3	AMCC-AEKF	1.149	1.117
	DGMCC-AEKF	1.004	0.987
方案 4	AMCC-AEKF	0.964	0.841
	DGMCC-AEKF	0.902	0.777

4 结语

针对传统 EKF 算法在非高斯噪声环境下估计精度不足、鲁棒性差的问题，本文引入了广义最大相关熵准则，同时提出了一种动态调整核宽的方法，通过计算残差的 3 次方来降低剧烈波动，并保留必要的波动信息，随后利用指数形式和迭代方法确定合适的核宽，提高了算法估计精度和鲁棒性。在自主搭建的实验平台上，经过 2 种工况验证表明，在非高斯噪声干扰下，DGMCC-AEKF 的准确性和鲁棒性均优于其他 3 种对比算法。此外，通过与其他自适应方法在 4 种噪声方案下的对比，体现出 DGMCC-AEKF 算法的优越性。

参考文献：

[1] 郭鹏旭，赵理，张丰硕. 基于随机充电片段的锂离子电池健康状态估计方法[J]. 电源学报，2026，24(6)：198-209.

Guo Pengxu, Zhao Li, Zhang Fengshuo. Method for estimating state-of-health of lithium batteries based on random charging segments [J]. Journal of Power Supply, 2026, 24(6): 198-209. (in Chinese)

[2] 刘旖琦，雷万钧，刘茜，等. 基于双自适应扩展粒子滤波器的锂离子电池状态联合估计[J]. 电工技术学报，

2024, 39(2): 607-616.
Liu Yiqi, Lei Wanjun, Liu Qian, et al. Joint state estimation of lithium-ion battery based on dual adaptive extended particle filter [J]. Transactions of China Electrotechnical Society, 2024, 39(2): 607-616. (in Chinese)

[3] 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)

[4] Pei Zhongwen, Liu Kaimin, Zhang Song, et al. Optimized EKF algorithm using TSO-BP neural network for lithium battery state of charge estimation [J]. Journal of Energy Storage, 2023, 73: 108882.

[5] Xie Yi, Li Wei, Hu Xiaosong, et al. Coestimation of SOC and three-dimensional SOT for lithium-ion batteries based on distributed spatial-temporal online correction [J]. IEEE Transactions on Industrial Electronics, 2023, 70(6): 5937-5948.

[6] Liu Zheng, Dang Xuanju, Jing Benqin, et al. A novel model-based state of charge estimation for lithium-ion battery using adaptive robust iterative cubature Kalman filter [J]. Electric Power Systems Research, 2019, 177: 105951.

[7] Duan Linchao, Zhang Xugang, Jiang Zhigang, et al. State of charge estimation of lithium-ion batteries based on second-order adaptive extended Kalman filter with correspondence analysis [J]. Energy, 2023, 280: 128159.

[8] 罗乐乐. 基于迭代扩展卡尔曼滤波的锂离子电池 SOC 估算[J]. 蓄电池, 2023, 60(2): 72-76.
Luo Lele. SOC estimation of lithium ion battery based on iterative extended Kalman filter [J]. Chinese LABAT Man, 2023, 60(2): 72-76. (in Chinese)

[9] Liu Zheng, Zhao Zhenhua, Qiu Yuan, et al. Enhanced state of charge estimation for Li-ion batteries through adaptive maximum correntropy Kalman filter with open circuit voltage correction [J]. Energy, 2023, 283: 128738.

[10] 王韦舒, 上官伟, 刘江, 等. 基于相关熵的自适应扩展卡尔曼滤波定位方法[J]. 铁道学报, 2022, 44(9): 71-78.
Wang Weishu, Shangguan Wei, Liu Jiang, et al. Adaptive extended Kalman filter positioning method based on correntropy criterion [J]. Journal of the China Railway Society, 2022, 44(9): 71-78. (in Chinese)

[11] Wang Lu, Ma Jian, Zhao Xuan, et al. Adaptive robust unscented Kalman filter-based state-of-charge estimation for lithium-ion batteries with multi-parameter updating [J]. Electrochimica Acta, 2022, 426: 140760.

[12] 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)

[13] Liu Zheng, Zhang Min, Song Xinmin, et al. A novel fusion maximum correntropy Kalman/UFIR filter for state estimation with uncertain non-Gaussian noise statistics [J]. Measurement, 2023, 220: 113339.

[14] Dang Lujuan, Huang Yulong, Zhang Yonggang, et al. Multi-kernelcorrentropy based extended Kalman filtering for state-of-charge estimation [J]. ISA Transactions, 2022, 129: 271-283.

[15] Huang Ce, Yu Xiaoyang, Wang Yongchao, et al. State of charge estimation of Li-ion batteries based on the noise-adaptive interacting multiple model [J]. Energy Reports, 2021, 7: 8152-8161.

[16] 刘政, 赵振华, 经本钦, 等. 基于自适应最大相关熵校正迭代卡尔曼滤波的电池 SOC 估算方法: CN116559694A[P]. 2023-08-08.



宋禹霆

作者简介：

宋禹霆(2000—　)，男，中国电源学会学生会员，硕士研究生。研究方向：动力电池状态估计。E-mail：1344981910@qq.com。

周俊(1985—　)，女，通信作者，博士，副教授。研究方向：机械故障诊断，电池状态监测。E-mail：710257592@qq.com。

(责任编辑：孙美菊)