基于片段充电数据和DUKF的锂电池健康状态实时评估

宋显华，孙文璐，谢 巍

（哈尔滨理工大学 理学院，哈尔滨 150080）

摘 要：精确实时地评估电池健康状况是电动汽车电池管理系统的核心，本文提出了一种新的电池全充时间估计模型。首先，利用无迹卡尔曼滤波处理非线性问题时的高估计精度，设计了精度进一步提升的双无迹卡尔曼滤波预测-校正框架，能精确估计锂电池当下的全充时间。在此框架下，利用高斯过程回归和支持向量回归预测结果做线性加权学习了无迹卡尔曼滤波的量测方程。实验结果表明：本文提出的框架具有高精度和实时性，估计180次全充时间的平均相对误差为0.001 6。与EKF和DEKF算法相比，平均相对误差分别减小了98.87%和98.15%。

关键词：电池健康状态；片段数据；双无迹卡尔曼滤波；高斯过程回归；支持向量回归

中图分类号：TM911 **文献标志码**：A **文章编号**：1671-5497(2026)02-0355-13

DOI：10.13229/j.cnki.jdxbgxb.20240871

Real-time estimation of Li-ion battery state of health based on segment charging data and DUKF

SONG Xian-hua, SUN Wen-lu, XIE Wei

(*School of Science*, *Harbin University of Science and Technology*, *Harbin* 150080, *China*)

Abstract: Accurate and real-time evaluation of the battery's state of health is the core of the battery management system in electric vehicles. This paper proposes a novel model for estimating the full charging time of lithium batteries. Firstly, utilizing the high estimation accuracy of the Unscented Kalman Filter for nonlinear problems, a dual Unscented Kalman Filter prediction correction framework with further improved accuracy is designed, which can accurately estimate the current full charge time of lithium batteries. Under this framework, the measurement equation of the Unscented Kalman Filter is linearly weighted using Gaussian Process Regression and Support Vector Regression prediction results. The experimental results show that the framework proposes in this paper has high accuracy and real-time performance, with an average relative error of 0.001 6 for estimating 180 full charge times. Compared with the EKF and DEKF based algorithms, the average relative error has reduced by 98.87% and 98.15%, respectively.

收稿日期：2024-08-04.

基金项目：山东省自然科学基金项目(ZR2022LLZ003)；国家自然科学基金项目(12471422).

作者简介：宋显华(1981-)女，副教授，博士.研究方向：机器学习和智能状态监测，图像安全和量子计算等.
E-mail：songxianhua@hrbust.edu.cn

Key words: state of health; segment data; dual unscented kalman filter; gaussian process regression; support vector regression

0 引 言

锂电池具有体积小、输出电压高和寿命长等优点,已成为新能源汽车的主要动力来源,广泛应用于航空航天、军事和医疗等领域[1,2]。在锂电池使用过程中,会长期进行循环充放电,因此,不可避免地出现电池容量衰减等不可逆问题。电池管理系统(Battery management system, BMS)在功率控制、寿命预测、充电管理和安全管理上扮演汽车管家的重要角色,BMS通过精准检测与评估电池的健康状态(State of health, SoH),有效实施风险信号预防性提示,从而保障电池能持续、安全且高效地长期运行。在BMS的运行和维护过程中,准确的电池SoH估计可以帮助BMS及时调整电池使用策略,避免过度放电或充电[3]。另一方面,实时的SoH估计可以及时发现电池性能衰退情况,预防潜在的安全风险,便于用户的维护。

目前,针对电动汽车锂电池SoH预测和估计的研究方法主要有直接测量法、模型法和数据驱动法[4,5]。直接测量法作为一种非实时性的方法,侧重于直接获取锂电池内部关键参数,如容量、内阻与电化学阻抗谱等,这些参数与电池的老化过程紧密相关。随后,构建关键参数和SoH的数学映射模型,从而实现对SoH的估算。文献[6]指出,商用18650电池的SoH可以通过其在316 Hz频率下的阻抗响应参数来间接表示。电化学阻抗谱(Electrochemical impedance spectroscopy, EIS)[7,8]具有丰富的电池SoH信息,其覆盖不同频率段的阻抗数据彼此间具有内在联系。若直接整合全频段的EIS数据作为输入,构建健康状态评估模型,会产生精度不足和计算复杂度增加等问题。基于EIS技术的直接测量法原理简单,适用于各类电池,但是对传感器等测量设备的要求较高,因此,难以在实验室之外的环境应用。

基于模型方法的SoH预测具有较高准确性和可靠性,常用模型方法有等效电路模型[9]、电化学模型[10]。等效电路模型运用常规电路元件来模拟电池的内部状态,并通过识别元件参数来预测SoH。例如,文献[11]建立了基于自回归等效电路模型,通过分析模型参数的不同特征,提出了一种差分模型参数识别策略,使用平方根无迹卡尔曼滤波实现电池SoH估计。而电化学模型则从电池的内部工作机制出发,运用偏微分方程组来描述电池容量衰退过程。文献[12]建立了基于化学计量比的电池正极容量计算法则,并考虑到正极老化对化学计量比的影响,提出了伪二维模型参数的SoH估计方法。基于模型的方法需要深入理解电池的内部机制和性能变化规律,同时,模型复杂性高、老化因素测试困难、实时预测难度大以及适用性受限等缺点。

数据驱动法在SoH的预测和估计中,避免了深入探究电池内部复杂的老化机制,而是采用机器学习等算法作为强大的工具,如支持向量机[13]、高斯过程回归[14-16]与神经网络[17,18]等,来建立电池外部健康特征与SoH之间的非线性映射关系。文献[19]针对局部充电电压和电流数据,提出了以径向基函数为核函数的支持向量机方法估计SoH;文献[20]利用Pearson相关分析方法从电池充放电曲线中提取了3个健康指标,建立集成高斯过程回归模型用于电池SoH估计。数据驱动的SoH预测方法在提高预测精度、减轻设备负担、实现实时性和动态性以及提供灵活性和可扩展性等方面具有优势。

和实验环境不同,电动汽车在实际使用中,往往根据车辆的行驶工况和用户充电习惯来充放电,因此,BMS系统获得的多是片段,且零散的充放电数据,此时,如何只利用这种片段数据来准确估计电池SoH显得尤为重要。周峭等[21]通过结合扩展卡尔曼滤波和高斯过程回归技术,实现了对电池SoH的实时估计。这一方法无须进行整个充放电操作过程,仅利用日常发生的片段充电数据,便能够估计出当前时刻电池所需的全充时间,进而估计出电池当下的SoH。这种实时估计在速度上表现出色,短期预测的相对误差在2%以下,基本符合实际应用需求,但长期的预测精度并不理想。为提高精度,文献[22]设计了双扩展卡尔曼滤波-小波神经网络-小波长短时神经网络相结合的电池SoH实时估计算法,该方法可以将短期预测的相对误差减小到1%左右,但在长期预测精度方面仍有待改进和优化。特别地,训练复杂的神经网络影响了该

方法实际使用时的实效性。

为同时解决SoH估计的精度和实时性问题，本文建立了双无迹卡尔曼滤波-高斯过程回归-支持向量回归(Dual unscented kalman filter-gaussian process regression and support vector regression，DUKF-GPR-SVR)框架。该框架通过融合先进的非线性状态估计技术和机器学习算法，实现了高精度和高效的SoH评估。首先，用一次全充数据训练融合的GPR和SVR模型，以确保这些模型能够捕捉到电池在完整充电周期中的复杂动态特性，为UKF的循环递推提供相应的输入值。然后，构建DUKF电池全充时间的实时评估框架，其中第一个UKF用于估计片段数据对应的全充时间，即使在不完整的充电过程中也能提供可靠的预测结果。第二个UKF用于实时修正当前循环次数下估计的全充时间，从而为下一次循环提供更为准确的状态初值，确保预测的连续性和稳定性。实验结果表明：本文算法短期和长期估计均表现出显著优势，平均绝对误差远远小于EKF-GPR和DEKF-WNN-WLSTM方法。此外，该算法在实时性方面也表现优异，能在短时间内完成复杂的计算任务，适用于需要快速响应的应用场景。

考虑到电动汽车实际应用中的复杂性和动力电池充电的片段性，如SoC从非零初始值(如40%或60%)充电至85%或满电状态不完整充电过程。这些片段数据难以精确反映电池的全面充电特性及剩余容量。为克服此局限，本文借鉴文献[21]的方法，利用从任意起始SoC的值至100%的片段充电数据，通过恒流充电模式下的数据分析，估算锂电池在当前状态下的全充时间，从而评估电池的SoH。这种方法不仅克服了传统方法在处理不完整充电数据时的局限性，还提高了对电池实际使用情况的适应能力。

1　相关工作

1.1　基于充电容量的锂电池SoH估计[21]

电池健康状态指电池在标准条件下，从满电以特定倍率放电至终止电压所释放的容量与原始标称容量的比值(百分比)。

$$\mathrm{SoH}=\frac{C_{\mathrm{M}}}{C_{\mathrm{N}}}\times 100\% \tag{1}$$

其中：C_{M}为测量的放电容量；C_{N}为电池标称的放电容量。

电池SoH描述了电池当下储存电量的能力，根据定义，从未被充放电电池的SoH值为1。

考虑到通过电池释放电量离线测试电池的SoH费时且操作不便，同文献[21,22]，本文采用充电容量C'_{M}与标称充电容量C'_{N}的比率来估算SoH，从而实现对电池SoH的有效评估。

$$\mathrm{SoH}\approx\mathrm{SoH}'=\frac{C'_{\mathrm{M}}}{C'_{\mathrm{N}}}\times 100\% \tag{2}$$

1.2　基于全充充电时间估计电池健康状态[21]

电池容量是指特定条件下，参与化学反应活性物质所释放的电量；也会定义为电池所能充入的最大电量。在恒流充电模式下，动力电池荷电状态(State of charge，SoC)公式如下：

$$C'_1=C'_0+\int_{t_0}^{t} I\mathrm{d}t \tag{3}$$

式中：C'_1为充电容量；C'_0为初始容量；I为电池充电电流；t为充电时长；即从t_0到截至电压所需的全部时间。

通常情况下，在充电效率一定时，电池从零容量开始充电至充满状态所用的时间越长，电池的容量也就越大。当电池持续充放电，恒流充电时间在不断减少[23]，这与SoH和电池的充电时间成正比，二者具有较强的相关性，基于此获得到电池的全充时间，即可得到电池的SoH。

1.3　无迹变换(Unscented transformation, UT)

设$\boldsymbol{y}=f(\boldsymbol{x})$为一个非线性变换，采用对称分布的UT变换。针对给定n维的随机状态向量$\boldsymbol{x}$，已知其均值$\bar{\boldsymbol{x}}$和方差$\boldsymbol{P}$，通过应用UT变换能够生成$2n+1$个采样点(称为Sigma点集)$\boldsymbol{X}$及其对应的权值ω，用于估算变换后向量$\boldsymbol{y}$的统计特性：

(1)计算$2n+1$个Sigma点$\boldsymbol{X}$，n为状态维数。

$$\begin{cases}\boldsymbol{X}^{(0)}=\bar{\boldsymbol{x}},\ i=0\\ \boldsymbol{X}^{(i)}=\bar{\boldsymbol{x}}+\left(\sqrt{(n+\lambda)\boldsymbol{P}}\right)_i,\ i=1,2,\cdots,n\\ \boldsymbol{X}^{(i)}=\bar{\boldsymbol{x}}-\left(\sqrt{(n+\lambda)\boldsymbol{P}}\right)_i,\ i=n+1,n+2,\cdots,2n\end{cases} \tag{4}$$

其中：$(\sqrt{\boldsymbol{P}})^{\mathrm{T}}(\sqrt{\boldsymbol{P}})=\boldsymbol{P}$，$(\sqrt{\boldsymbol{P}})_i$表示矩阵方根的第$i$列。

(2)计算采样点$\boldsymbol{X}$对应的权值：

$$\begin{cases}\omega_m^{(0)}=\dfrac{\lambda}{n+\lambda}\\ \omega_c^{(0)}=\dfrac{\lambda}{n+\lambda}+(1-\alpha^2+\beta)\\ \omega_m^{(i)}=\omega_c^{(i)}=\dfrac{\lambda}{2(n+\lambda)},\ i=1,2,\cdots,2n\end{cases} \tag{5}$$

式中:m为均值;c为协方差,i为第i个采样点。$\beta \geqslant 0$是一个非负的权系数。参数$\lambda = a^2(n+\kappa)-n$是缩放比,$a$控制采样点的分布状态,待选参数$\kappa$用来确保$(n+\lambda)P$为半正定矩阵。

1.4 无迹卡尔曼滤波(Unscented Kalman filter, UKF)

UKF作为非线性滤波的一种方法[24],旨在解决传统卡尔曼滤波器在非线性系统下性能受限的问题。该方法避免了传统方法对非线性函数进行Taylor级数展开的要求,从而规避了由此带来的近似误差问题。

非线性系统在不同时刻k的状态可由式(4)进行描述,其中随机变量$x(k)$和观测变量$z(k)$均具有高斯白噪声$w(k)$、$v(k)$。

$$\begin{cases} \boldsymbol{x}(k) = f\big(\boldsymbol{x}(k-1), \boldsymbol{w}(k)\big) \\ \boldsymbol{z}(k) = h\big(\boldsymbol{x}(k), \boldsymbol{v}(k)\big) \end{cases} \tag{6}$$

式中:非线性的状态和量测方程为f和h,以及$w(k)$和$v(k)$具有协方差矩阵$\boldsymbol{Q}$和$\boldsymbol{R}$。

1.5 高斯过程回归(Gaussian process regression, GPR)[21]

高斯过程是描述随机变量的分布并且可以决定函数属性,从函数空间的角度叫作贝叶斯推断。其核心在于通过均值和协方差函数来刻画该过程在函数空间中的统计性质,对于任意一组随机变量$\{x_p \in X, p = 1, 2, \cdots, N\}$,其过程状态的联合分布$\{f(x_1), f(x_2), \cdots, f(x_N)\}$在高斯过程中呈现出$N$维高斯分布的特性。

$$\begin{cases} m(x_p) = E\big[f(x_p)\big] \\ k(x_p, x_q) = E\big[(m(x_p) - f(x_p))(m(x_q) - f(x_q))\big] \end{cases} \tag{7}$$

式中:$x_p, x_q \in \boldsymbol{R}^n$为随机变量。

高斯过程可定义为:

$$f(x) \sim \mathrm{GP}(m(x), k(x_p, x_q)) \tag{8}$$

设$D = (\boldsymbol{X}, \boldsymbol{y}) = \{(\boldsymbol{x}_1, \boldsymbol{y}_1), (\boldsymbol{x}_2, \boldsymbol{y}_2), \cdots, (\boldsymbol{x}_N, \boldsymbol{y}_N)\}$是$N$个观测数据,$\boldsymbol{X} = [\boldsymbol{x}_1 \quad \boldsymbol{x}_2 \quad \cdots \quad \boldsymbol{x}_N]$为训练输入数据,是由$N$个$n$维矢量$\boldsymbol{x}_i$组合成的$n \times N$维矩阵,$\boldsymbol{y} = [\boldsymbol{y}_1 \quad \boldsymbol{y}_2 \quad \cdots \quad \boldsymbol{y}_N]^{\mathrm{T}}$为训练输出标量的联合输出矢量,$\boldsymbol{y}_i \in \boldsymbol{R}$。

考虑如下回归模型:

$$\boldsymbol{y}_p = f(\boldsymbol{x}_p) + \varepsilon_p \tag{9}$$

式中:输入值为$\boldsymbol{x}_p$($p = 1, 2, \cdots, N$);f是输入和输出之间的映射关系;输出值为$\boldsymbol{y}_p$($p = 1, 2, \cdots, N$);加性高斯噪声ε_p服从均值为0,方差是σ_N^2。

在高斯过程回归框架下,模型通过从训练数据中学习非线性映射关系$\big[f(\cdot): \boldsymbol{R}^n \mapsto \boldsymbol{R}\big]$,能对新的输入$x_*$预测$y_*$。观测值$\boldsymbol{y}$与预测值$f_*$的联合分布函数为:

$$\begin{bmatrix} \boldsymbol{y} \\ f_* \end{bmatrix} \sim N\left\{0, \begin{bmatrix} k(\boldsymbol{X}, \boldsymbol{X}) + \sigma_M^2 I & k(\boldsymbol{X}, x_*) \\ k(x_*, \boldsymbol{X}) & k(x_*, x_*) \end{bmatrix}\right\} \tag{10}$$

式中:$k(\boldsymbol{X}, x_*)$为训练集与预测值的协方差函数;$k(x_*, x_*)$为预测值的协方差函数。

在贝叶斯线性回归框架下,一旦模型参数设定了先验分布,通过结合观测到的数据,即可得参数的后验分布

$$f_* | \boldsymbol{X}, \boldsymbol{y}, x_* \sim N(\overline{f_*}, \mathrm{Cov}(f_*)) \tag{11}$$

$$\overline{f_*} = k(x_*, x_*)\,[k(\boldsymbol{X}, \boldsymbol{X}) + \sigma_N^2 I\,]^{-1}\boldsymbol{y} \tag{12}$$

$$\mathrm{Cov}(f_*) = k(x_*, x_*) - k(x_*, \boldsymbol{X})[k(\boldsymbol{X}, \boldsymbol{X}) + \sigma_N^2 I\,]^{-1}k(\boldsymbol{X}, x_*) \tag{13}$$

高斯过程根据不同的应用场景和数据特性,选择不同类型的核函数。

1.6 支持向量回归(Support vector regression, SVR)

SVR作为一种有效的预测工具,在时间序列分析领域得到了广泛应用,其擅长处理小样本数据集、有效应对非线性问题,同时展现出对时间序列数据好的适应性和强大的泛化性能[25]。

在给定样本集$S = \{x_i, y_i\}_{i=1}^n$的前提下,其中每个样本由输入向量$\boldsymbol{x}_i, \boldsymbol{x}_i \in R^n$和对应的输出向量$\boldsymbol{y}_i, \boldsymbol{y}_i \in \boldsymbol{R}$组成。SVR方法利用一种特定的非线性映射机制,将原始的低维数据空间映射至更高维的特征空间,此非线性映射的定义为:

$$f(x) = \omega\phi(x) + b \tag{14}$$

式中:x为输入数据;ω为权重;$\phi(x)$为非线性映射函数;b为截距。

$f(x)$可等价于一个优化问题的求解:

$$\frac{1}{2}\|\omega\|^2 + C\sum_i^n L\big(f(x_i), y_i\big) \tag{15}$$

式中:L为损失函数为;C为惩罚因子。

进而得到了SVR的非线性映射表达式:

$$f(x) = \omega\phi(x) + b = \sum_{i=1}^n (\alpha_i - \alpha_i^*)K(x_i, x) \tag{16}$$

式中:$K(x_i, x) = \phi(x_i)\phi(x_j)$为核函数。

径向基函数在逼近能力、结构简单性和泛化能力等方面都展现出了优势。因此，选取径向基函数作为核函数。

$$K_{\mathrm{RBF}}(x_i,x)=\exp\left(-\gamma\left\|x_i-x\right\|^2\right) \quad (17)$$

式中：γ为核参数，$\gamma=1/(2\sigma^2)$。

2　双无迹卡尔曼滤波-高斯过程回归-支持向量回归算法

2.1　无迹卡尔曼滤波-高斯过程回归

本文采用GPR来估计UKF的状态方程、量测方程以及噪声协方差矩阵。具体而言，训练数据$\boldsymbol{D}_{r-1}=\left(z_{r-1}(1),z_{r-1}(2),\cdots,z_{r-1}(N)\right)$是前一循环的量测结果，即$x_r(k)$为当前循环中的第$k$个状态量，也是GPR的输入数据。状态方程、量测方程由GP表示：

$$x_r(k)=\mathrm{GP_f}\left(\left[x_r(k-1),u_r(k-1)\right]\right)+w(k-1) \quad (18)$$

$$z_r(k)=\mathrm{GP_h}\left(\left[\boldsymbol{D}_{r-1},x(k)\right]\right)+v(k) \quad (19)$$

$$w_k\sim N\left(0,\mathrm{GP_f^R}\left[x(k-1),u(k-1)\right]\right) \quad (20)$$

$$v_k\sim N\left(0,\mathrm{GP_h^Q}\left(\boldsymbol{D}_{r-1}\right)\right) \quad (21)$$

式中：GP为高斯过程回归函数；$\boldsymbol{R}$、$\boldsymbol{Q}$为噪声方差。

考虑到SoH历史数据普遍展现出整体下降与局部再生性特征，采用线性函数$m(x)=ax+b$为GPR的均值函数

$$k(x_p,x_q)=k_1(x_p,x_q)+k_2(x_p,x_q) \quad (22)$$

式中：$k_1(x_p,x_q)$为神经网络协方差函数；$k_2(x_p,x_q)$为周期协方差函数：

$$k_1\left(x_p,x_q\right)=\sigma_{\mathrm{f_1}}^2\sin^{-1}\left[\frac{x_i^{\mathrm{T}}\boldsymbol{\Lambda}^{-2}x_j}{\sqrt{\left(1+x_i^{\mathrm{T}}\boldsymbol{\Lambda}^{-2}x_i\right)\left(1+x_j^{T}\boldsymbol{\Lambda}^{-2}x_j\right)}}\right] \quad (23)$$

其中$\boldsymbol{\Lambda}=\mathrm{diag}(l_1^{-2})$：

$$k_2\left(x_p,x_q\right)=\sigma_{\mathrm{f_2}}^2\left[-\frac{2}{l_2^2}\sin^2\left(\frac{\varpi}{2\pi}\left(x_i-x_j\right)\right)\right] \quad (24)$$

超参数为$hpy=\left[a,b,l_1,\sigma_{\mathrm{f_1}},l_2,\varpi,\sigma_{\mathrm{f_2}}\right]^{\mathrm{T}}$。

2.2　双无迹卡尔曼滤波-高斯过程回归-支持向量回归算法(DUKF-GPR-SVR)算法

传统的电池SoH评估方法通常依赖于单一模型，如EKF、简单机器学习算法或单一回归方法，这些方法在处理复杂的非线性系统时存在局限性。本文提出了一种新颖的DUKF-GPR-SVR框架，该框架将DUKF、GPR和SVR的优势有机结合起来。通过多模型融合，实现了对复杂动态系统的高效处理和精确预测。DUKF避免了传统方法中线性化的误差累积问题，能在不牺牲计算复杂度的情况下提供更精确的状态估计。GPR不仅提供了点估计，还给出了预测结果的置信区间，使模型能更好适应数据中的噪声和异常值。SVR通过优化支持向量选择和核函数的应用，增强了模型的泛化性能，从而提高了长期预测的可靠性。3种方法的结合有效抑制了误差累积，减小了单一模型可能存在的偏差，显著提升了整体预测精度。

DUKF-GPR-SVR算法具备快速收敛的特点，能在短时间内完成状态估计和更新，适用于需要实时监控的应用场景，如电动汽车和储能系统。通过持续学习新的片段数据，该算法能够自动调整模型参数，以应对不同工况下的变化，确保长期稳定运行。准确的SoH预测有助于优化充电策略、预警潜在故障，从而降低维护成本并延长电池使用寿命。

本文将GPR-SVR融入无迹卡尔曼滤波中，采用GPR-SVR网络以及双无迹卡尔曼滤波提高系统模型预测性能，流程如图1所示，τ为循环数的上限，具体的递归估计过程如下：

算法一：DUKF-GPR-SVR实时估计算法

步骤1　初始化充电参数：恒流充电I为1.49 A，恒压充电截止电压为4.34 V，在初次充电循环r_0中，恒流充电的全充数据是$d_0=(t_0(k),v_0(k))$，$k=1,2,\cdots,n_0$，当截止电压为4.34 V时，时间总采样点数n_0，时间间隔$\Delta T=t_0(k+1)-t_0(k)$为固定常数，第k个采样点的电压为$v_0(k)$。

步骤2　高斯过程回归和支持向量回归

利用线性均值函数，周期与神经网络协方差函数相加的复合协方差函数对恒流充电过程中的全充数据d_0进行GPR，以及计算初始超参数hpy_0。

惩罚因子直接决定了SVR方法的准确性。本文选取惩罚因子4.0作为折中值，允许的不敏感损失值设为0.01，使用径向基函数作为核函数对全充数据d_0进行支持向量回归。利用GPR和SVR分别学习UKF_1量测方程，并根据对应的估

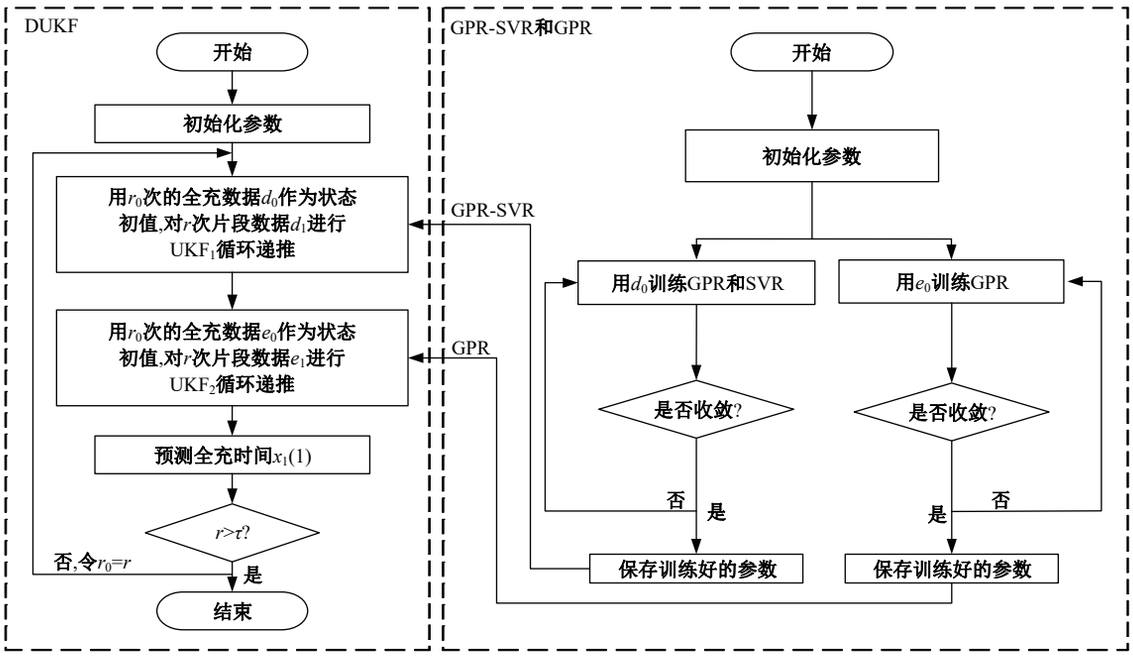

图1 DUKF-GPR-SVR流程图

Fig. 1 Flowchart of DUKF-GPR-SVR

计误差,采用加权平均方法分配权重,得到最终的量测方程。

步骤3 无迹卡尔曼滤波一

利用r_0次的全充数据d_0作为状态初值,状态向量初始化$x_1(1)=t_0(n)$,片段数据为$d_1=(t_1(k),v_1(k))$,$k=1,2,\cdots,n_1$。接下来,对r次的片段数据进行UKF-GPR-SVR,估计第r次恒流充电所需要的全充时间:

(1)状态方程

$$x_1(k)=x_1(k-1)-\Delta T+\omega_1(k-1) \tag{25}$$

(2)测量方程

$$z_1(k)=\mathrm{GP-SVR}(d_0,x_1(k))+v_1(k) \tag{26}$$

式中:GP-SVR代表利用d_0做GPR与SVR训练,以及预测状态$x_1(k)$的电压值$z_1(k)$。

步骤4 无迹卡尔曼滤波一循环递推

(1)应用无迹变换,产生一组采样点$\boldsymbol{X}_1$,并分配相应权值,式中$i=1,2,\cdots,2n+1$。

$$\boldsymbol{X}_1^{(i)}(k|k)=\left[\bar{x}_1(k|k)\quad \bar{x}_1(k|k)+\left(\sqrt{(n+\lambda)\boldsymbol{P}_1(k|k)}\right)_i\cdot \bar{x}_1(k|k)-\left(\sqrt{(n+\lambda)\boldsymbol{P}_1(k|k)}\right)_{n+i}\right] \tag{27}$$

(2)对$i=1,2,\cdots,2n+1$计算$2n+1$个Sigma点集的预测。

$$\boldsymbol{X}_1^{(i)}(k+1|k)=f\left(k,\boldsymbol{X}_1^{(i)}(k|k)\right) \tag{28}$$

(3)状态量的预测及协方差矩阵是通过将Sigma点集的预测值进行加权处理,进而求其均值和协方差。

$$\hat{x}_1(k+1|k)=\sum_{i=0}^{2n}\omega_1^{(i)}\boldsymbol{X}_1^{(i)}(k+1|k)$$

$$\boldsymbol{P}_1(k+1|k)=\sum_{i=0}^{2n}\omega_1^{(i)}\left[\hat{x}_1(k+1|k)-\boldsymbol{X}_1^{(i)}(k+1|k)\right]\left[\hat{x}_1(k+1|k)-\boldsymbol{X}_1^{(i)}(k+1|k)\right]^{\mathrm{T}}+\boldsymbol{Q}_1 \tag{30}$$

(4)根据预测值$\hat{x}_1(k+1|k)$,利用UT变换产生新的Sigma点集,式中$i=1,2,\cdots,2n+1$。

$$\boldsymbol{X}_1^{(i)}(k+1|k)=[\hat{x}_1(k+1|k)\cdot \hat{x}_1(k+1|k)+(\sqrt{(n+\lambda)\boldsymbol{P}_1(k+1|k)})_i \hat{x}_1(k+1|k)-(\sqrt{(n+\lambda)\boldsymbol{P}_1(k+1|k)})_{n+i}] \tag{31}$$

(5)当$i=1,2,\cdots,2n+1$时,将更新后的的Sigma点集输入观测方程,从而计算出预测的观测量。

$$z_1^{(i)}(k+1|k)=h_1\left(\boldsymbol{X}_1^{(i)}(k+1|k)\right) \tag{32}$$

(6)加权求和,进而得到观测量预测的均值和协方差:

$$\bar{z}_1(k+1|k)=\sum_{i=0}^{2n}\omega_1^{(i)}z_1^{(i)}(k+1|k) \tag{33}$$

$$\boldsymbol{P}_{1z_kz_k}=\sum_{i=0}^{2n}\omega_1^{(i)}\left[z_1^{(i)}(k+1|k)-\bar{z}_1(k+1|k)\right]\left[z_1^{(i)}(k+1|k)-\bar{z}_1(k+1|k)\right]^{\mathrm{T}}+\boldsymbol{R}_1 \quad (34)$$

$$\boldsymbol{P}_{1x_kz_k}=\sum_{i=0}^{2n}\omega_1^{(i)}\left[\boldsymbol{X}_1^{(i)}(k+1|k)-\bar{z}_1(k+1|k)\right]\left[z_1^{(i)}(k+1|k)-\bar{z}_1(k+1|k)\right]^{\mathrm{T}} \quad (35)$$

(7)计算Kalman增益矩阵：

$$\boldsymbol{K}_1(k+1)=\boldsymbol{P}_{1x_kz_k}\boldsymbol{P}_{1z_kz_k}^{-1} \quad (36)$$

(8)最后，进行状态和协方差更新：

$$\hat{x}_1(k+1|k)=\hat{x}_1(k+1|k)+\boldsymbol{K}_1(k+1)\left[z_1(k+1|k)-\hat{z}_1(k+1|k)\right] \quad (37)$$

$$\boldsymbol{P}_1(k+1|k)=\boldsymbol{P}_1(k+1|k)-\boldsymbol{K}_1(k+1)\boldsymbol{P}_{1z_kz_k}\boldsymbol{K}_1^{\mathrm{T}}(k+1) \quad (38)$$

式中：$\boldsymbol{R}_1$和$\boldsymbol{Q}_1$分别为噪声$w_1(k)$和$v_1(k)$的协方差矩阵。

步骤5　无迹卡尔曼滤波二

提取片段数据$d_1=(t_1(k),v_1(k))$，$k=1,2,\cdots,n_1$，对片段数据进行$\mathrm{UKF_1}-\mathrm{GPR}-\mathrm{SVR}$循环递推，并保存状态方程和每次输出的状态值和测量值$d_1^*=(t_1^*(k),v_1^*(k))$，$k=1,2,\cdots,n_1$。最后，用$d_1^*-d_1$得到GPR的训练数据$e_0=(\Delta t_1(k),\Delta v_1(k))$，$k=1,2,\cdots,n_1$。提取$r=r_0+1$次$\mathrm{UKF_1}$的状态和测量误差数据$e_1=(\Delta t_1(k),\Delta v_1(k))$，$k=1,2,\cdots,n_1$，状态的初值设为第$r_0$次片段的累积误差$e_0$，状态向量初值$\boldsymbol{x}_1(1)=0$，对$r$次恒流的片段进行无迹卡尔曼滤波-高斯过程回归($\mathrm{UKF_2}$-GPR)循环递推，估计第$r$次恒流充电$\mathrm{UKF_1}$预测的全充时间与真实时间误差：

(1)状态方程

$$x_2(k)=x_2(k-1)-\Delta t/100+w_2(k-1) \quad (39)$$

(2)量测方程

$$z_2(k)=\mathrm{GP}(e_1,x_2(k))+v_2(k) \quad (40)$$

式中：GP表示通过GPR来预测状态$x_2(k)$的电压值$z_2(k)$；$\mathrm{UKF_1}$估计相邻两次全充时间的差值为Δt。

步骤6　无迹卡尔曼滤波二循环递推

利用UT变换，生成了$2n+1$个Sigma点$\boldsymbol{X}_2$的集合，并为每个点分配相应的权重ω_2。

预测：

$$\hat{x}_2(k+1|k)=\sum_{i=0}^{2n}\omega_2{}^{(i)}\,\boldsymbol{X}_2{}^{(i)}(k+1|k) \quad (41)$$

$$\boldsymbol{P}_2(k+1|k)=\sum_{i=0}^{2n}\omega_2{}^{(i)}\left[\hat{x}_2(k+1|k)-\boldsymbol{X}_2{}^{(i)}(k+1|k)\right] \quad (42)$$

$$\left[\hat{x}_2(k+1|k)-\boldsymbol{X}_2{}^{(i)}(k+1|k)\right]^{\mathrm{T}}+\boldsymbol{Q}_2 \quad (43)$$

通过得到的预测值，再次运用UT变换来产生一组新的Sigma点集，代入量测方程中，得出预测的观测结果，其中$i=1,2,\cdots,2n+1$。

$$z_2^{(i)}(k+1|k)=h_2\left[X_2^{(i)}(k+1|k)\right] \quad (44)$$

进行加权求和得出预测的均值及其对应的协方差矩阵：

$$\bar{z}_2(k+1|k)=\sum_{i=0}^{2n}\omega_2^{(i)}z_2^{(i)}(k+1|k) \quad (45)$$

$$\boldsymbol{P}_{2z_kz_k}=\sum_{i=0}^{2n}\omega_2^{(i)}\left[z_2{}^{(i)}(k+1|k)-\bar{z}_2(k+1|k)\right]\left[z_2{}^{(i)}(k+1|k)-\bar{z}_2(k+1|k)\right]^{\mathrm{T}}+\boldsymbol{R}_2 \quad (46)$$

$$\boldsymbol{P}_{2x_kz_k}=\sum_{i=0}^{2n}\omega_2{}^{(i)}\left[\boldsymbol{X}_2{}^{(i)}(k+1|k)-\bar{z}_2(k+1|k)\right]\left[z_2{}^{(i)}(k+1|k)-\bar{z}_2(k+1|k)\right]^{\mathrm{T}} \quad (47)$$

计算Kalman增益矩阵：

$$\boldsymbol{K}_2(k+1)=\boldsymbol{P}_{2x_kz_k}\boldsymbol{P}_{2z_kz_k}^{-1} \quad (48)$$

最后，进行计算状态更新以及协方差更新：

$$\hat{x}_2(k+1|k)=\hat{x}_2(k+1|k)+\boldsymbol{K}_2(k+1)\cdot\left[z_2(k+1|k)-\hat{z}_2(k+1|k)\right] \quad (49)$$

$$\boldsymbol{P}_2(k+1|k)=\boldsymbol{P}_2(k+1|k)-\boldsymbol{K}_2(k+1)\boldsymbol{P}_{2z_kz_k}{}^{\mathrm{T}}\boldsymbol{K}_2^{\mathrm{T}}(k+1) \quad (50)$$

式中：$\boldsymbol{R}_2$和$\boldsymbol{Q}_2$分别为噪声$w_2(k)$和$v_2(k)$的协方差。

步骤7　预测全充时间与真实的全充时间的误差：

$$E=x_2(n_1) \quad (51)$$

步骤8　预测全充时间：计算r次片段数据全充时间：

$$x_1(1)=x_1(n_1)+\left[\Delta T\times n_1-1\right]-E \quad (52)$$

步骤9 更新循环：

令$r_0=r$，$\left(t_0(k),v_0(k)\right)=\left(x_1(k),v_1(k)\right)$，重复步骤3～8至循环上限。

3　实验仿真及其分析

本文采用深圳新威尔电子公司提供的三元锂电池充放电数据库作为验证基准，有效评估了所提出算法的效能。在实验环节，测试了一种采用$\mathrm{LiNi_xCo_yMnzO_2}$化学成分的电池，标称电压为

3.78 V,标称容量为3.5 Ah。电池先在2 100 mA恒流下充电至8.4 V,随后,采用相同电流将电池放电至5.6 V,其充放电过程具体表现如图2和图3所示。实验首先验证了DUKF-GPR-SVR算法的有效性,与EKF-GPR以及DEKF-WNN-WLSTM进行对比,验证本文算法性能的提高,最后用DUKF算法估计全充时间评估电池的健康状态。

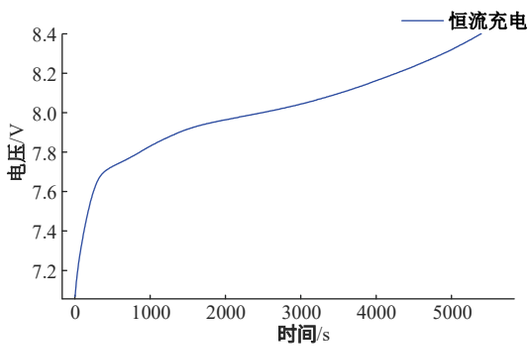

图2 恒流充电模式

Fig. 2 Constant current charging mode

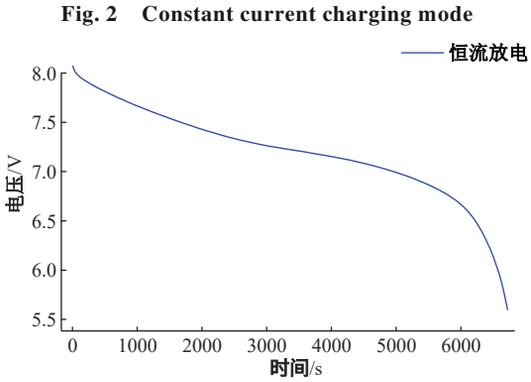

图3 恒流放电模式

Fig. 3 Constant current discharging mode

3.1 仿真软件介绍

实验运行的硬件环境配备了Intel Core i7-10510U处理器,该处理器基础频率为1.80 GHz,并能在需要时加速至2.30 GHz。此平台运行于Windows 11家庭中文版64位操作系统之上,并配备了16 GB运行内存。编程软件选取了Matlab 2022a作为编程环境来执行相关实验。

3.2 DUKF-GPR-SVR短期预测全充时间

图4展示了本文算法估计的电池全充时间和真实全充时间的对应关系,可以观察到,除极少数变化较显著的周期外,两者的变化趋势整体上呈现出高度的一致性。本文所引入的DUKF-GPR-SVR算法,在仅依赖日常充电片段数据的条件下,能在极低的误差阈值内精确预测电池全充所需时间。

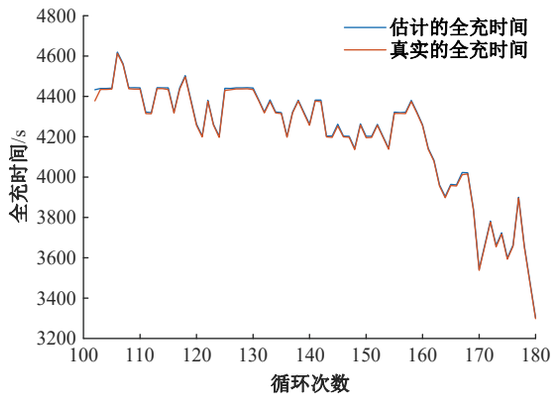

图4 估计的全充时间和真实的全充时间

Fig. 4 Estimated whole charging time and true whole charging time

图5~图7详细介绍了本文算法在80次估计过程中产生的绝对误差、相对误差及其绝对值的情况。通过对相对误差绝对值的分析,计算得出整个估计序列的平均相对误差低至0.001 4。由于电池初始充放电阶段的性能不稳定,在实际应用中初始阶段的电池性能良好,直接参考价值有限,因此,本文舍弃前100次的电池数据,选用第

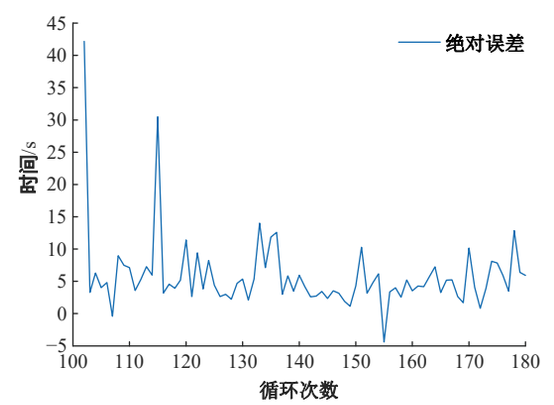

图5 估计全充时间的绝对误差

Fig. 5 Absolute error of estimated full charge time

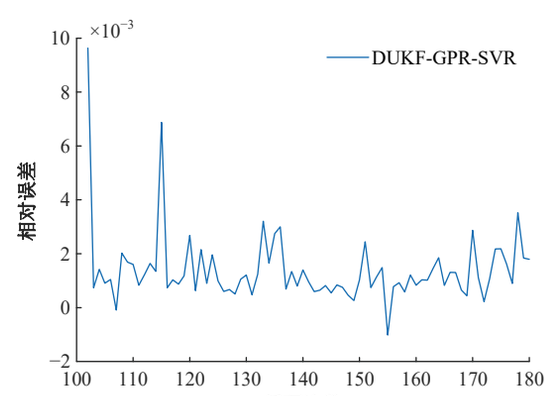

图6 估计全充时间的相对误差

Fig. 6 Relative error of estimated full charge time

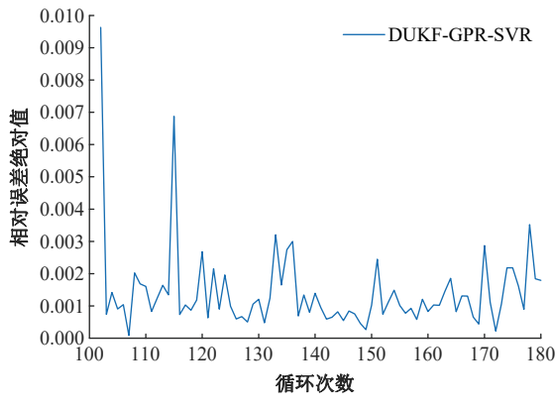

图 7　估计全充时间的相对误差绝对值

Fig. 7　Absolute value of relative error of estimated full charge time

101次循环数据作为初始全充数据。从3幅图中可以看到，整体循环中估计全充时间的误差完全小于1%，大多数时刻小于0.4%。由于对UKF_1的状态初值进行了一定的修正，从50次之后的误差也在0.4%以内，验证了本文算法的准确性和有效性。

3.3　消融实验

为全面评估本文方法在评估锂电池SoH方面的有效性，本与5种不同的基础模型进行比较分析：DUKF-GPR、DUKF-SVR、UKF-GPR、UKF-SVR以及UKF-GPR-SVR，以阐明本文模型在评估锂电池SoH方面的有效性，如图8～图10所示，分别对估计的绝对误差、相对误差和相对误差绝对值进行了可视化对比，结果表明，本文方法在这3个误差指标上均表现出色，显示出较低的误差水平，并且优于其他方法。

表1展示了6种不同方法的平均相对误差对比，可以看出，本文算法在所有预测方法中均表现出最小的平均相对误差。较低的误差值反映了该

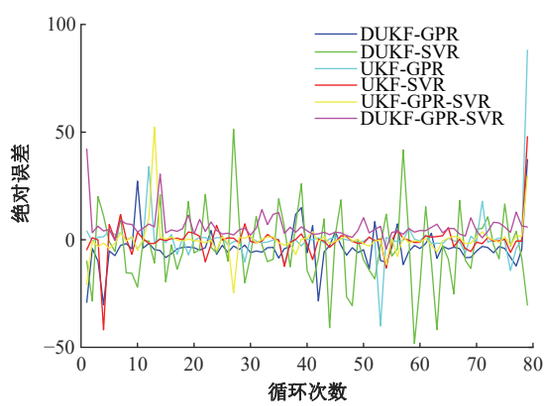

图 8　6种方法的绝对误差

Fig. 8　Absolute error of six methods

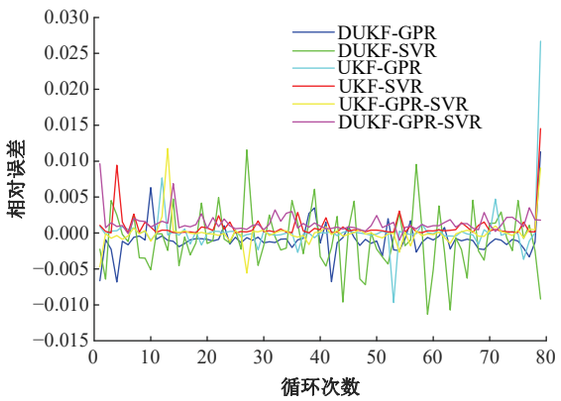

图 9　6种方法的绝对误差

Fig. 9　Absolute error of six methods

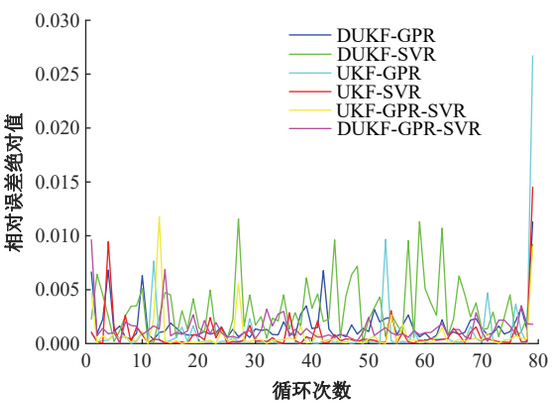

图 10　6种方法的绝对误差

Fig. 10　Absolute error of six methods

表 1　6种方法估计的平均相对误差

Table 1　Average relative error of six methods

指标	DUKF-GPR	DUKF-SVR	UKF-GPR	UKF-SVR	UKF-GPR-SVR	DUKF-GPR-SVR
Average	0.001 9	0.003 1	0.002 7	0.003 3	0.002 6	0.001 4

算法在处理数据和进行预测时的高度准确性，验证了其在实际应用中的有效性和优越性。

3.4　短期全充时间估计

为进一步证明本文方法的准确性，本节与周頔等[21]和宋显华等[22]提出的基于EKF-GPR与DEKF-WNN-WLSTM方法进行比较。图11为短期(100～180 cycles)3种估计方法的全充时间和真实的全充时间对比，可以看出，本文算法相比于上述两种算法更接近真实值。鉴于电池系统固有的复杂非线性特性，DUKF作为一种扩展的卡尔曼滤波器，能更准确地处理非线性系统，因此，在特定应用场景下展现出了突出的优势。GPR通过精心设计的核函数，对数据集进行先验建模；SVR通过优化支持向量的选择，并借助核技巧，

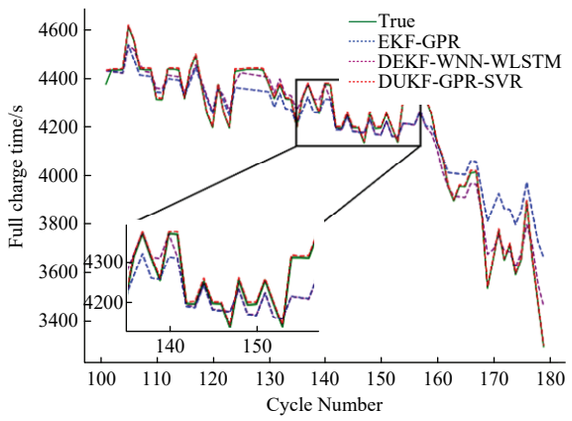

图11 3种估计方法的结果比较

Fig. 11 Comparison results of the three estimation methods

能高效地对数据集进行非线性映射,二者均能精准捕捉数据间复杂的非线性关系,实现高精度的回归预测。随着循环次数的增加,DUKF-GPR-SVR这一综合方法有效抑制了误差累积,避免了因误差累积导致的预测偏差,这使得在无须定期进行完全充放电以重置初始全充时间值的额外操作下,本文算法展现出了更为优越的估计性能,确保了更为准确和稳定的电池SoH评估。

表2为3种方法的平均相对误差,EKF-GPR的平均相对误差为0.017 6;DEKF-WNN-WLSTM的平均相对误差为0.010 1,进一步说明本文方法准确性高的优点。

图12~图14分别为3种估计方法的绝对误差、相对误差和相对误差绝对值。可以发现:DUKF-GPR-SVR相对于DEKF-WNN-WLSTM和EKF-GPR而言,其误差曲线普遍低于后者,尤其是循环次数在165~180次时,它们之间的误差曲线相差最远,这说明本文方法具有较强的预测能力。

表2 3种方法短期估计的平均相对误差

Table 2 Average relative error of three methods

指标	EKF-GPR	DEKF-WNN-WLSTM	DUKF-GPR-SVR
Average	0.0176	0.0101	0.0014

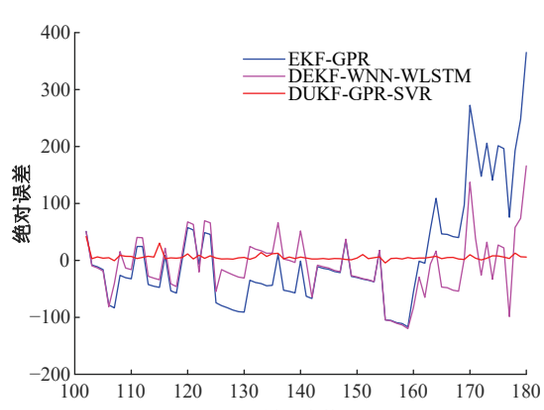

图12 3种方法的绝对误差

Fig. 12 Absolute error of three methods

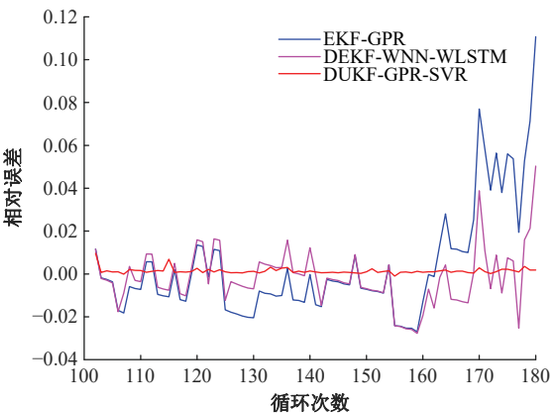

图13 3种方法的相对误差

Fig. 13 Relative error of the three methods

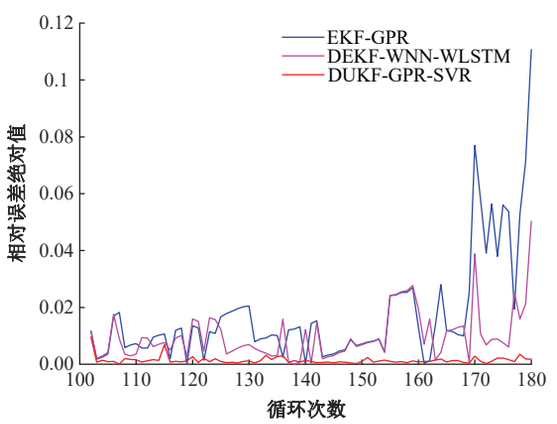

图14 3种方法相对误差的绝对值

Fig. 14 Absolute value of relative error of the three methods

3.5 长期全充时间估计

图15是3种算法估计长期(100~280 cycles)全充时间和真实的全充时间对比。可以看到,除个别变化较快的周期外,本文算法DUKF-GPR-SVR与真实值变化基本完全一致。这说明本文算法也能够充分利用日常片段充电数据,精确地预测电池在较长周期内的全充时间。

表3是3种算法的平均相对误差,EKF-GPR的平均相对误差为0.141 8;DEKF-WNN-WLSTM的平均相对误差为0.086 4,这一结果显示,本文的DUKF-GPR-SVR方法不仅在短期预测中表现出色,在长期预测中同样保持了较高的精

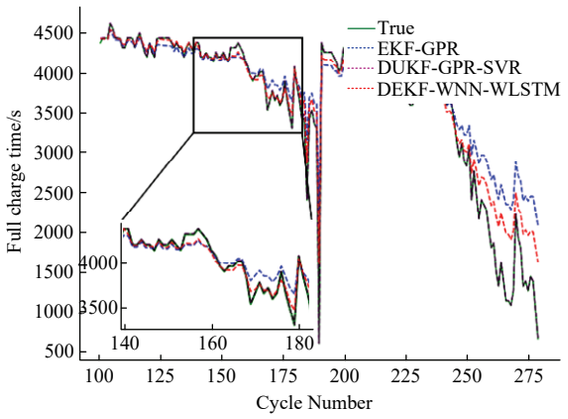

图 15　3种方法估计的全充时间

Fig. 15　Estimated SoH of the three methods

表 3　3种方法长期估计的平均相对误差

Table 3　Average relative error of three methods

指标	EKF-GPR	DEKF-WNN-WLSTM	DUKF-GPR-SVR
Average	0.1418	0.0864	0.0016

确度。较低的平均相对误差表明该方法能更准确地捕捉系统动态，并有效减小预测偏差。因此，本文方法在长期预测中的优越性能得到了充分验证，展示出其在实际应用中的潜力。

3.6　运行时间

除精度外，计算速度和响应时间也是实时预测系统需要的评估指标。表 4 是 3 种方法短期(80 cycles)运行时间对比，EKF-GPR算法预测的平均运行时间为 10 s，显示出较高的时间效率。相比之下，DEKF-WNN-WLSTM算法由于网络结构复杂，运行时间较长，显著影响了实时性能。综合考虑时间和精度两个关键因素，本文设计的算法在两者间取得了良好的平衡。经100次实验结果分析，DUKF-GPR-SVR算法平均运行时间约为28 s，进一步证明了本文方法性能优良。

表 5 为 3 种方法长期(180 cycles)的平均运行时间比较，EKF-GPR 的平均运行时间为 14 s；DEKF-WNN-WLSTM 的平均运行时间较长。相对于 EKF-GPR，本文方法的运行时间有所增加，但这也反映了其在处理复杂计算和模型融合方面的深入程度，确保了更高的预测精度和稳定性。这种增强的能力对于保障锂电池 SoH 的准确评估至关重要，尤其是在需要长时间监控和预测的应用场景中，能够在合理的时间范围内完成实时估计，证明了其在实际应用中的可行性和可靠性。

表 4　短期运行时间比较

Table 4　Short term running time comparison

指标	EKF-GPR	DEKF-WNN-WLSTM	DUKF-GPR-SVR
时间/s	10	>>3 600	28

表 5　长期运行时间比较

Table 5　Long term running time comparison

指标	EKF-GPR	DEKF-WNN-WLSTM	DUKF-GPR-SVR
时间/s	14	>>3 600	47

3.7　实时 SoH 估计分析

本文基于充电容量进行评估电池健康状态的模型如式(3)所示。基于式(2)(3)的分析，可以推断出电池 SoH 与全充时间呈正比关系，这一结论是在设定恒流充电 I 和放电标称容量为 C_N 得出的。图 4 直观地展示了电池 SoH 的估计值随全充时间的延长而逐渐下降的趋势，同时，这一趋势中还包含局部性的回升现象，体现了电池性能的动态变化。假设取 $I=2.1$ A，$C_N=3.5$ Ah，3 种方法估计的 SoH 如图 16 所示。

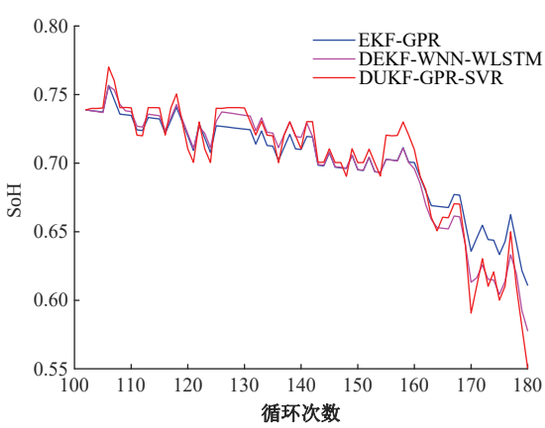

图 16　3种方法估计的 SoH

Fig. 16　Estimated SoH of the three methods

4　结束语

在确保锂电池安全高效运行的过程中，准确且实时的 SoH 评估是至关重要的，因此，本文提出了一种新的算法框架，该框架融合 DUKF、GPR 与 SVR 的技术优势，并巧妙利用日常片段的充电数据，实现了对锂电池 SoH 的准确高效估计。其核心思想是利用高斯过程回归-支持向量回归良好的学习和预测性能，去学习无迹卡尔曼滤波的量测方程。在设定的噪声范围内，可实时

对电池健康状态进行评估,有利于电池的维护以及电动汽车在生活中的广泛使用。仿真实验结果表明:相比于EKF-GPR以及DEKF-WNN-WL-STM两者的电池SoH实时估计模型,本文方法能有效缓解误差的累积,相对误差绝对值基本可以控制在0.4%以内,具有良好的长期预测性能。

参考文献:

[1] Wen G, Yuan S, Dong Z, et al. Recycling of spent lithium iron phosphate battery cathode materials: a review[J]. Journal of Cleaner Production, 2024, 474: 143625.

[2] Hopkins B J, Bashian N H. Modernizing rechargeable military batteries[J]. Joule, 2024, 8(8): 2178-2182.

[3] Nyamathulla S, Dhanamjayulu C. A review of battery energy storage systems and advanced battery management system for different applications: challenges and recommendations[J]. Journal of Energy Storage, 2024, 86: 111179.

[4] Dai H, Zhao G, Lin M, et al. A novel estimation method for the state of health of lithium-ion battery using prior knowledge-based neural network and Markov chain[J]. IEEE Transactions on Industrial Electronics, 2018, 66(10): 7706-7716.

[5] Yang B, Qian Y, Li Q, et al. Critical summary and perspectives on state-of-health of lithium-ion battery [J]. Renewable and Sustainable Energy Reviews, 2024, 190: 114077.

[6] Love C T, Virji M B V, Rocheleau R E, et al. State-of-health monitoring of 18650 4S packs with a single-point impedance diagnostic[J]. Journal of Power Sources, 2014, 266: 512-519.

[7] Hu W, Peng Y, Wei Y, et al. Application of electrochemical impedance spectroscopy to degradation and aging research of lithium-ion batteries[J]. The Journal of Physical Chemistry C, 2023, 127(9): 4465-4495.

[8] Koseoglou M, Tsioumas E, Ferentinou D, et al. Lithium plating detection using dynamic electrochemical impedance spectroscopy in lithium-ion batteries[J]. Journal of Power Sources, 2021, 512: 230508.

[9] Çarkıt T, Alçı M. Investigation of VoC and SoH on Li-ion batteries with an electrical equivalent circuit model using optimization algorithms[J]. Electrical Engineering, 2022: 1-12.

[10] Gao Y, Liu K, Zhu C, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model[J]. IEEE Transactions on Industrial Electronics, 2021, 69(3): 2684-2696.

[11] Liu F, Shao C, Su W, et al. Online joint estimator of key states for battery based on a new equivalent circuit model[J]. Journal of Energy Storage, 2022, 52: 104780.

[12] 高仁璟, 吕治强, 赵帅, 等. 基于电化学模型的锂离子电池健康状态估算[J]. 北京理工大学学报: 自然科学版, 2022, 42(8): 791-797.
Gao Ren-jing, Lv Zhi-qiang, Zhao Shuai, et al. Health state estimation of lithium-ion batteries based on electrochemical models[J]. Journal of Beijing Institute of Technology (Natural Science Edition), 2022, 42 (8): 791-797.

[13] Yao L, Fang Z, Xiao Y, et al. An intelligent fault diagnosis method for lithium battery systems based on grid search support vector machine[J]. Energy, 2021, 214: No. 118866.

[14] Zhou D, Fu P, Yin H, et al. A study of online state-of-health estimation method for in-use electric vehicles based on charge data[J]. IEICE Transactions on Information and Systems, 2019, 102(7): 1302-1309.

[15] Jia J, Liang J, Shi Y, et al. SOH and RUL prediction of lithium-ion batteries based on gaussian process regression with indirect health indicators[J]. Energies, 2020, 13(2): 375.

[16] 王萍, 弓清瑞, 张吉昂, 等. 一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J]. 电工技术学报, 2021, 36(24): 5201-5212.
Wang Ping, Gong Qing-rui, Zhang Ji-ang, et al. An online state of health prediction method for lithium batteries based on combination of data-driven and empirical model[J]. Transactions of China Electrotechnical Society, 2021, 36(24): 5201-5212.

[17] Qu J, Liu F, Ma Y, et al. A neural-network-based method for RUL prediction and SOH monitoring of lithium-ion battery[J]. IEEE Access, 2019, 7: 87178-87191.

[18] Guo Y, Yang D, Zhang Y, et al. Online estimation of SOH for lithium-ion battery based on SSA-Elman neural network[J]. Protection and Control of Modern Power Systems, 2022, 7(3): 1-17.

[19] Chen Z, Sun M, Shu X, et al. Online state of health estimation for lithium-ion batteries based on support vector machine[J]. Applied Sciences, 2018, 8(6): No. 925.

[20] Wang J, Deng Z, Yu T, et al. State of health estimation based on modified Gaussian process regression for lithium-ion batteries[J]. Journal of Energy Storage, 2022, 51: 104512.

[21] 周頔, 宋显华, 卢文斌, 等. 基于日常片段充电数据的锂电池健康状态实时评估方法研究[J]. 中国电机工程学报, 2019, 39(1): 105-111.
Zhou Di, Song Xian-hua, Lu Wen-bin, et al. Real-time SOH estimation algorithm for lithium-ion batteries based on daily segment charging data[J]. Proceedings of the CSEE, 2019, 39(1): 105-111.

[22] 宋显华, 姚全正. 基于片段充电数据和 DEKF-WNN-WLSTM 的锂电池健康状态实时估计[J]. 电工技术学报, 2024, 39(5): 1565-1576.
Song Xian-hua, Yao Quan-zheng. Real time estimation of lithium battery state of health based on segment charging data and DEKF-WNN-WLSTM[J]. Transactions of China Electrotechnical Society, 2024, 39(5): 1565-1576.

[23] Yang D, Zhang X, Pan R, et al. A novel gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve[J]. Journal of Power Sources, 2018, 384: 387-395.

[24] 黄小平. 卡尔曼滤波原理及应用: MATLAB 仿真[M]. 北京: 电子工业出版社, 2022.

[25] Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning, 1995, 20: 273-297.