

DOI: 10.19783/j.cnki.pspc.250101

# 考虑噪声影响的电动汽车动力电池 SOH 和 RUL 联合估计

孙立明, 余涛

(华南理工大学电力学院, 广东 广州 510641)

**摘要:** 电动汽车动力电池状态的监测和估计对于提高其安全、稳定运行有着重要意义。为解决电池健康状态(state of health, SOH)和剩余使用寿命(remaining useful life, RUL)估计中存在的健康特征难以提取以及模型受噪声影响程度大等问题, 考虑数据噪声对于估计模型的影响, 提出了一种基于 ICEEMDAN-DO-GRU 的强鲁棒性估计模型实现对电动汽车动力电池 SOH 和 RUL 的准确估计。首先, 利用一种基于改进的自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)方法对 NASA 公开的电池数据集进行信号分解以提取用于模型估计的健康特征。其次, 使用蒲公英优化器(dandelion optimizer, DO)对门控循环单元(gated recurrent unit, GRU)的隐藏层神经元数目和初始学习率进行优化以提高 GRU 的性能。最后, 研究了所提模型在不同噪声影响下的有效性, 并将 DO-GRU 的结果与其他 4 种典型的神经网络进行对比分析。实验结果表明, 所提 ICEEMDAN-DO-GRU 模型在 SOH 和 RUL 估计方面有较高的准确性和较强的鲁棒性。

**关键词:** 动力电池; 健康状态估计; 剩余寿命估计; ICEEMDAN; 蒲公英优化器; 门控循环单元

## Joint estimation of SOH and RUL for electric vehicle power batteries considering noise effects

SUN Liming, YU Tao

(School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China)

**Abstract:** Monitoring and estimating the state of electric vehicle power batteries are of great significance for ensuring their safe and stable operation. To address the challenges in estimating the battery state of health (SOH) and remaining useful life (RUL), specifically the difficulty in extracting health-related features and the strong sensitivity of models to noise, a highly robust estimation model based on ICEEMDAN-DO-GRU is proposed, fully accounting for the impact of data noise on model performance. First, the ICEEMDAN decomposition method is used to perform signal decomposition on NASA's publicly available battery dataset to extract health features for model estimation. Second, the dandelion optimizer (DO) is used to optimize the number of hidden layer neurons and the initial learning rate of the gated recurrent unit (GRU), thereby improving its performance. Finally, the effectiveness of the proposed model under different noise conditions is studied, and the DO-GRU results are comprehensively compared with four other typical neural networks. The experimental results prove that the proposed ICEEMDAN-DO-GRU model achieves high accuracy and strong robustness in both SOH and RUL estimation.

This work is supported by the National Natural Science Foundation of China for Enterprise Innovation and Development (No. U24B6010).

**Key words:** power battery; state of health estimation; remaining useful life estimation; ICEEMDAN; dandelion optimizer; gated recurrent unit

## 0 引言

随着“碳达峰”、“碳中和”目标的提出以及可

再生能源技术的快速发展, 电动汽车、储能电站迎来了巨大的发展机遇<sup>[1]</sup>。其中, 锂电池相较于铅酸电池等传统电池, 能量密度更高、自放电率更低、使用寿命更长。

目前锂电池已被广泛用于电动汽车动力电池以及大型储能系统等领域<sup>[2-3]</sup>。然而, 锂电池在实际运

**基金项目:** 国家自然科学基金企业创新发展联合基金项目资助(U24B6010)

行过程中,随着运行时间的增加,电池内部的一些副反应会导致电池内阻的升高以及可用容量的减少,这一现象被称作锂电池的老化。此外,由于锂电池在实际运行过程中,运行工况的复杂性以及电池所处环境的多样性,会加速其老化,进而给后续电池的安全、稳定运行带来严重挑战<sup>[4]</sup>。因此,电池管理系统(battery management system, BMS)对于监测电池运行状态以及维护电池安全稳定运行具有重要意义,其中,健康状态(state of health, SOH)估计尤为重要,因为其直接关乎电池能否稳定运行<sup>[5-6]</sup>。除此之外,剩余使用寿命(remaining useful life, RUL)的预测对电池研究也具有重要意义,因为其可以为电池后续的运行提供指导<sup>[7]</sup>。

目前国内外已经对锂电池 SOH 和 RUL 估计展开了相关研究,主要分为两个大类,即模型法和数据驱动法。模型法的能够准确地反映电池内部复杂的机理、估计精度更高,但针对电池的建模较为复杂、计算量大。而数据驱动法则相对简单,估计精度高、速度快,因此目前开展了大量与数据驱动法相关的研究,并取得了许多成果<sup>[8]</sup>。

文献[9]利用模拟退火算法和遗传算法来优化反馈(back propagation, BP)神经网络以提高锂电池 SOH 的估计精度,其选用 NASA 公开数据集对估计模型进行实验验证,结果证明,与传统 BP 神经网络得到的结果相比,优化后的模型具备更高的估计精度。文献[10]提出利用灰狼优化算法对双向长短期记忆神经网络的模型参数进行优化来提高估计性能,从电池充电数据中提取健康特征作为估计模型的输入,实验证明该模型估计精度良好、鲁棒性强。文献[11]利用引力搜索算法来优化支持向量回归模型,并结合从充电曲线中提取的健康特征对锂电池的 SOH 和 RUL 进行联合估计,实验结果证明该模型有着较高的预测精度和较强的鲁棒性。文献[12]在遗传算法优化 BP 神经网络的基础上,利用数据信息度构建动量因子来保证神经网络的迭代收敛速度,通过对电池老化数据进行 SOH 和 RUL 估计实验,证明该方法具有良好的可行性和有效性。文献[13]提出了一种基于改进麻雀搜索算法优化高斯回归过程的锂电池 SOH 估计模型,该模型利用改进后的麻雀搜索算法优化高斯过程回归的参数,分析电池的容量增量曲线,提取表征电池老化的健康特征作为估计模型的输入,实验结果表明该方法能够对锂电池的 SOH 进行准确估计。

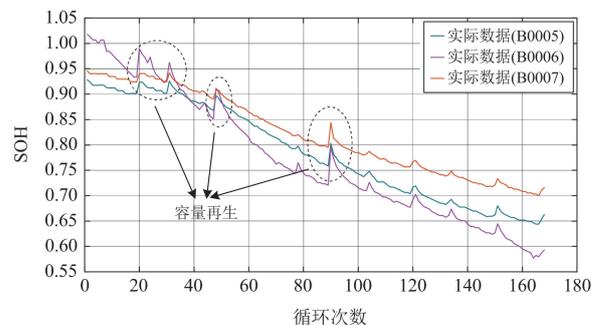
上述研究主要是通过对模型进行改进来提高锂电池 SOH 和 RUL 的估计精度,并没有考虑数据集

本身可能会受到噪声污染进而影响最终的估计精度的问题。因此,本文提出了一种基于改进自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)结合蒲公英优化器(dandelion optimizer, DO)优化门控循环单元(gated recurrent unit, GRU)的 ICEEMDAN-DO-GRU 锂电池 SOH 和 RUL 联合估计模型,通过 ICEEMDAN 对电池数据集进行分解以提取表征电池老化的健康特征,并利用优化后的 GRU 模型来对 SOH 和 RUL 进行估计。此外,考虑到实际运行中的测量数据可能会受到噪声影响,本文研究了在不同噪声影响情况下所提模型的有效性。将所提模型得到的估计结果与 BP 神经网络<sup>[14]</sup>、极限学习机(extreme learning machine, ELM)<sup>[15]</sup>、径向基函数(radial basis function, RBF)<sup>[16]</sup>和卷积神经网络(convolutional neural network, CNN)-长短期记忆神经网络(long and short term memory, LSTM)<sup>[17]</sup>在不同电池数据下的实验结果进行比较,证明本文所提 ICEEMDAN-DO-GRU(下文简称 DO-GRU)估计模型能够准确估计锂电池的 SOH 和 RUL,具备强鲁棒性和泛化性。

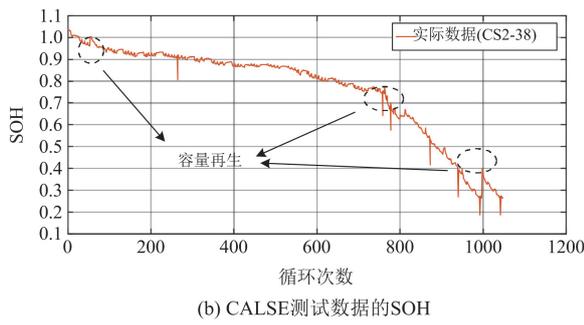
## 1 健康特征提取及关联度分析

### 1.1 数据集介绍

本文所用锂电池老化数据来自美国 NASA 公开的锂电池测试数据<sup>[18]</sup>和马里兰大学公开的 CALCE 锂电池的 CS2-38 数据集<sup>[19]</sup>。其中 NASA 数据集在测试过程中针对电池的测试步骤主要分为恒流-恒压充电以及恒流放电两个步骤,实验中 3 块标称容量 2 Ah 的电池在 24 °C 的恒温条件下进行; CALSE 数据集采用 3 块标称容量 1.1 Ah 的电池在不同的温度和放电倍率下进行,图 1 为两个数据集的 3 块电池最终测试得到的 SOH 退化曲线。由图 1 可知,电池的 SOH 随着循环次数的增加呈下降趋势,在局部区域出现了 SOH 回升现象,这种现象被称为锂电池的容量回升,其是导致锂电池 SOH 估计呈非线性的重要因素。



(a) NASA测试数据的SOH



(b) CALSE测试数据的SOH

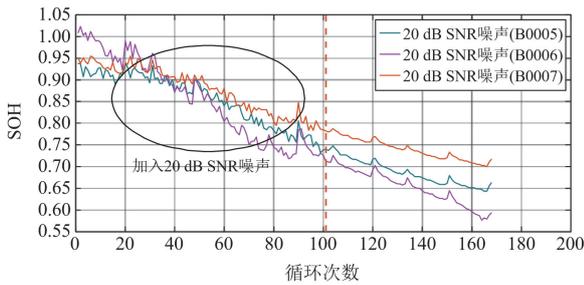
图 1 不同数据集的锂电池 SOH 退化曲线图

Fig. 1 SOH degradation curve of lithium batteries of different dataset

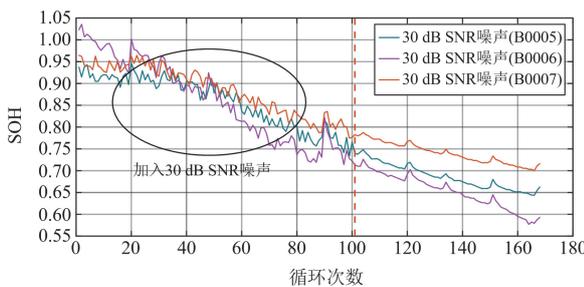
除此之外, 为了研究本文所提模型针对含噪声数据情况下 SOH 估计的准确性, 对 NASA 和 CALCE 数据集分别加入了信噪比(signal to noise ratio, SNR)为 20 dB 和 30 dB 的噪声信号对模型进行二次验证, 图 2 为加入噪声后锂电池的 SOH 退化曲线。

### 1.2 健康特征提取及关联度分析

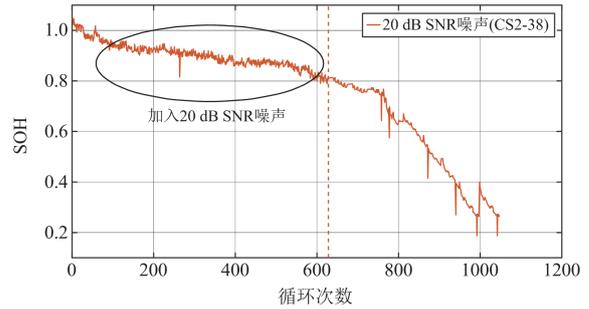
由于锂电池退化曲线的非线性, 本文利用 ICEEMDAN 对锂电池老化数据进行分解来获取电池的健康特征<sup>[20]</sup>, 图 3—图 6 分别表示 B0005、B0006、B0007 和 CS2-38 电池数据集的 ICEEMDAN 分解结果。ICEEMDAN 算法将 B0005、B0006、B0007 的原始数据分别分解为 5 个子序列, 其中包括 4 个本征模态分量和 1 个残差分量; 将 CS2-38 原始数据分解为 7 个子序列, 其中包括 6 个本征模态分量和 1 个残差分量, 以提高估计模型输入的数据质量。



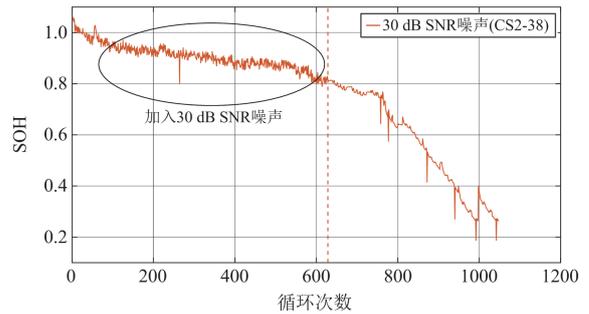
(a) NASA数据集加入20 dB SNR噪声的SOH



(b) NASA数据集加入30 dB SNR噪声的SOH



(c) CALSE数据集加入20 dB SNR噪声



(d) CALSE数据集加入30 dB SNR噪声

图 2 不同 SNR 下的锂电池 SOH 退化曲线图

Fig. 2 SOH degradation curves of lithium batteries at different SNRs

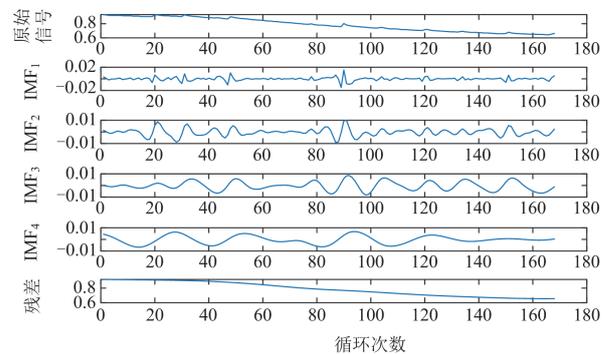


图 3 B0005 数据集的 ICEEMDAN 分解结果

Fig. 3 ICEEMDAN decomposition results of B0005 dataset

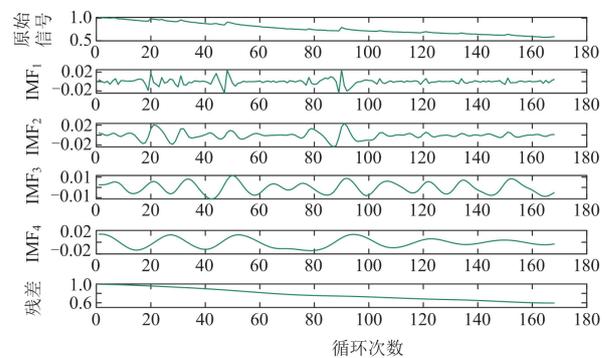


图 4 B0006 数据集的 ICEEMDAN 分解结果

Fig. 4 ICEEMDAN decomposition results of B0006 dataset

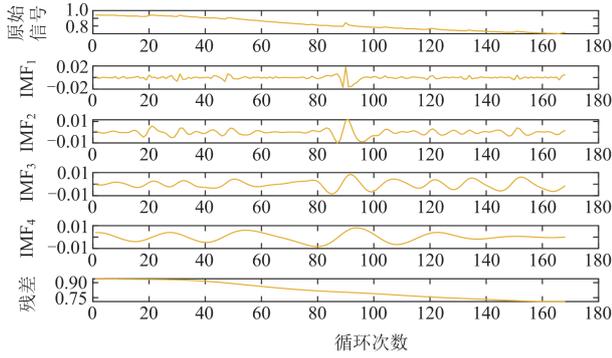


图5 B0007数据集的ICEEMDAN分解结果

Fig. 5 ICEEMDAN decomposition results of B0007 dataset

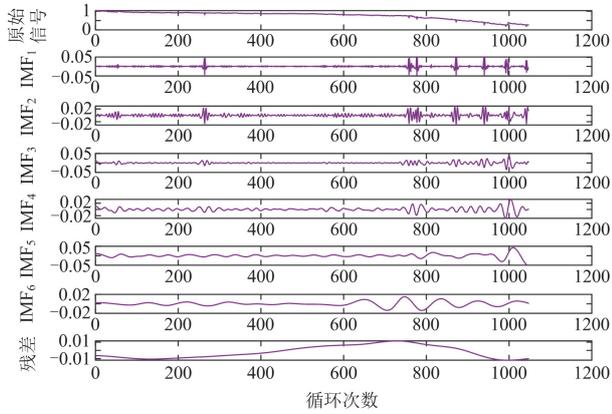


图6 CS2-38数据集的ICEEMDAN分解结果

Fig. 6 ICEEMDAN decomposition results of CS2-38 dataset

本文采用灰色关联度对特征分量进行关联度分析,表1为ICEEMDAN分解后的特征分量与电池原始SOH的关联度。可以看出,各分量与电池的SOH退化曲线均有着较高的关联度,因此将其作为最终估计模型的输入。

表1 不同数据集的特征分量灰色关联度结果

Table 1 Grey relation results of characteristic components of different dataset

数据集	IMF <sub>1</sub>	IMF <sub>2</sub>	IMF <sub>3</sub>	IMF <sub>4</sub>	IMF <sub>5</sub>	IMF <sub>6</sub>	残差
B0005	0.8185	0.7749	0.6203	0.8578	—	—	0.9975
B0006	0.7822	0.7845	0.6288	0.8350	—	—	0.9947
B0007	0.9206	0.8592	0.6247	0.9257	—	—	0.9994
CS2-38	0.9151	0.8993	0.9555	0.9402	0.9574	0.9432	0.9989

## 2 DO与GRU估计模型

### 2.1 DO模型

DO模型主要是模拟蒲公英种子传播过程中依靠风力进行长距离飞行,其主要分为上升、下降和落地3个阶段,各阶段的数学模型如下<sup>[21]</sup>。

#### 1) 上升阶段

晴天时,蒲公英种子在风速的影响下会被随机吹到各个位置,风速越快,飞得越远,因此,上升阶段蒲公英种子个体的位置更新公式为

$$x_i^{t+1} = x_i^t + \alpha \cdot v_x \cdot v_y \cdot \ln Y \cdot (x_{\text{rand}}^t - x_i^t) \quad (1)$$

式中:  $x_i^t$  表示当前种群中第  $i$  个个体在第  $t$  次迭代中所处的位置;  $\alpha$  表示一个自适应参数,用于调整搜索步长;  $v_x$  和  $v_y$  表示蒲公英种子由于涡流分离作用而产生的升力系数;  $x_{\text{rand}}^t$  表示搜索空间内产生的随机数;  $\ln Y$  表示服从  $\mu=0$ 、 $\sigma^2=1$  的对数正态分布,其表达式为

$$\ln Y = \begin{cases} \frac{1}{y\sqrt{2\pi}} \cdot e^{-\frac{1}{2\sigma^2}(\ln y)^2}, & y \geq 0 \\ 0, & y < 0 \end{cases} \quad (2)$$

式中:  $y$  表示标准正态分布  $(0,1)$ 。

$$\alpha = \text{rand} \cdot \left( \frac{1}{T^2} \cdot t^2 - \frac{2}{T} \cdot t + 1 \right) \quad (3)$$

式中:  $\text{rand}$  表示一个  $(0,1)$  之间的随机数;  $T$  表示算法的最大迭代次数。

$$\begin{cases} v_x = \frac{1}{e^\theta} \cdot \cos \theta \\ v_y = \frac{1}{e^\theta} \cdot \sin \theta \end{cases} \quad (4)$$

式中:  $\theta$  表示  $[-\pi, \pi]$  之间的随机数。

雨天时,蒲公英种子无法上升,而是在当前位置附近盘旋,此时蒲公英种子的位置更新公式为

$$\begin{cases} x_i^{t+1} = x_i^t \cdot k \\ k = 1 - \text{rand} \cdot q \\ q = \frac{t^2}{T^2 - 2T + 1} - \frac{2t}{T^2 - 2T + 1} + \frac{1}{T^2 - 2T + 1} + 1 \end{cases} \quad (5)$$

式中:  $k$  用于调整蒲公英种子的局部搜索区域;  $q$  为控制局部搜索区域随迭代次数的动态调整参数。

综上所述,蒲公英种子在上升阶段的位置更新公式为

$$x_i^{t+1} = \begin{cases} x_i^t + \alpha \cdot v_x \cdot v_y \cdot \ln Y \cdot (x_{\text{rand}}^t - x_i^t), & \text{randn} < 1.5 \\ x_i^t \cdot k, & \text{其他} \end{cases} \quad (6)$$

式中:  $\text{randn}$  为服从标准正态分布的随机数。

#### 2) 下降阶段

下降阶段主要是通过引入布朗运动以及采用上升阶段后的平均位置信息,使得种群朝着更有潜力的区域靠近,此阶段的数学模型为<sup>[22]</sup>

$$x_i^{t+1} = x_i^t - \alpha \cdot \beta \cdot (x_{\text{mean}}^{t+1} - \alpha \cdot \beta \cdot x_i^{t+1}) \quad (7)$$

式中:  $\beta$  表示服从正态分布的布朗运动随机数;  $x_{\text{mean}}^{t+1}$  表示第  $t+1$  次迭代时,蒲公英种子上升阶段后

的平均位置。

### 3) 落地阶段

在前两个阶段的基础上, 蒲公英种子随机选择落地点, 随着迭代次数的增加, 算法最终收敛到全局最优解。在落地阶段蒲公英种子个体利用当前种子精英个体的位置, 在局部领域中搜索更新, 其位置更新公式为

$$x_i^{t+1} = x_{\text{elite}}^t + \text{Levy}(\lambda) \cdot \alpha \left( x_{\text{elite}}^t - x_i^{t+1} \cdot \frac{2t}{T} \right) \quad (8)$$

式中:  $x_{\text{elite}}^t$  表示第  $t$  次迭代蒲公英种子的最优位置;  $\text{Levy}(\lambda)$  表示莱维飞行函数。

## 2.2 GRU

GRU 是循环神经网络的一种变体, 其模型主要包括更新门和重置门。更新门确定前一时间信息的保留程度, 重置门控制前一时间信息在当前信息的遗忘程度<sup>[23]</sup>。GRU 的网络结构如图 7 所示<sup>[24]</sup>。

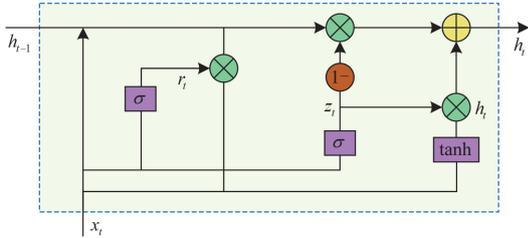


图 7 GRU 结构图

Fig. 7 Diagram of GRU structure

GRU 的数学模型如式(9)一式(12)所示。

$$r_t = \sigma \cdot (\mathbf{w}_r \cdot [h_{t-1}, \mathbf{w}_r x_t]) \quad (9)$$

$$z_t = \sigma \cdot (\mathbf{w}_z \cdot [h_{t-1}, \mathbf{w}_z x_t]) \quad (10)$$

$$\tilde{h}_t = \tanh(\mathbf{w}_h \cdot [r_t \cdot h_{t-1}, x_t]) \quad (11)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (12)$$

式中:  $\mathbf{w}_r$ 、 $\mathbf{w}_z$  和  $\mathbf{w}_h$  分别表示重置门、更新门和隐藏层的权值矩阵;  $h_t$  和  $h_{t-1}$  分别表示当前时间和前一时间的隐藏状态;  $r_t$  和  $z_t$  分别表示更新门与重置门在  $t$  时刻的状态, 留存的上一时刻的旧信息越多, 其数值越接近 1, 反之, 其数值越接近于 0;  $\sigma$  表示 sigmoid 激活函数;  $\tanh$  表示双曲正切激活函数。

## 2.3 DO-GRU 模型

本文采用 DO 对 GRU 网络中的隐藏层神经元个数和初始学习率进行优化以提高估计模型的整体性能。隐藏层神经元个数会影响模型的拟合程度, 神经元个数太少会导致训练时间增加, 容易出现欠拟合; 个数太多时, 信息量不足以训练所有神经元, 容易导致过拟合。初始学习率则会影响模型的收敛情况, 当初始学习率过小, 模型的收敛速度较

慢, 而当初始学习率过大, 模型容易产生梯度爆炸等问题。

综上所述, 本文提出的 DO-GRU 锂电池 SOH 和 RUL 估计模型的参数设置如表 2 所示, 具体实施步骤如图 8 所示。首先对电池的老化数据进行 ICEEMDAN 分解, 提取用于估计的特征分量; 然后设置 GRU 网络的模型参数, 并利用 DO 对 GRU 网络的隐藏层神经元个数和初始学习率进行优化;

表 2 各模型参数设置

Table 2 Parameters setting of various models

模型	参数	参数设置
GRU	最大迭代次数	1000
	输入维度	5
	隐藏层权重丢失率	0.003
BP	最大迭代次数	1000
ELM	隐藏层神经元个数	5
RBF	最大迭代次数	1000
CNN-LSTM	最大迭代次数	1000
	优化器	Adam
DO	种群数	10
	算法最大迭代次数	20
	隐藏层搜索区间	[10 200]
	初始学习率搜索区间	[0.001 0.1]

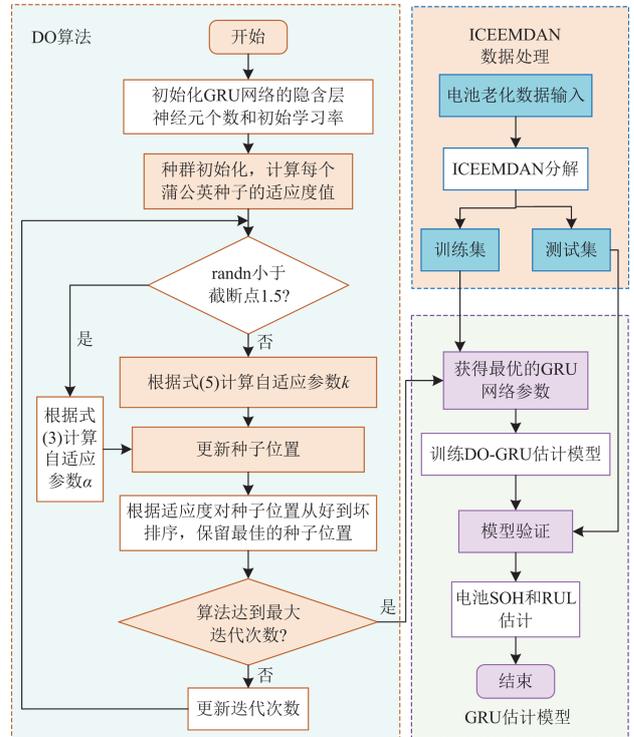


图 8 ICEEMDAN-DO-GRU 估计流程图

Fig. 8 ICEEMDAN-DO-GRU estimation flowchart

最后将电池老化数据分为训练集和测试集,利用训练集对估计模型进行训练,并对测试集进行模型验证。

### 2.4 评估指标

本文采用误差(error, E)、平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)3个指标来评估最终的实验结果,用绝对误差(absolute error, AE)来评估RUL的估计结果<sup>[25]</sup>,各评估指标如式(13)一式(16)所示。

$$e_E = \hat{y}_i - y_i \quad (13)$$

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (14)$$

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (15)$$

$$e_{AE} = |t_{actual} - t_{estimate}| \quad (16)$$

式中:  $y_i$  表示第  $i$  次循环时电池的实际 SOH 值;  $\hat{y}_i$  表示第  $i$  次循环时模型估计得到的 SOH 值;  $N$  表示电池的总循环次数;  $t_{actual}$  表示电池实际剩余使用寿命;  $t_{estimate}$  表示模型估计得到的电池剩余使用寿命。

## 3 实验验证及结果分析

本文所提模型在 MATLAB 2022a 中搭建,并在 Inter(R) Core(TM) CPU 的计算机上进行了模型效果的实验验证。

### 3.1 SOH 估计结果分析

本文利用所提 DO-GRU 模型提取健康特征对锂电池的 SOH 和 RUL 进行估计,分别对 B0005、B0006、B0007 和 CS2-28 数据集进行实验验证,前 60% 的数据作为训练集,后 40% 的数据作为测试集,并将最终的估计结果与 BP、ELM、RBF 和 CNN-LSTM 这 4 种模型得到的结果进行比较。同时为了验证 DO-GRU 模型的鲁棒性,对用于验证的 B0005、B0006、B0007 和 CS2-38 电池训练数据施加不同噪声信号来模拟电池在实际运行过程中可能受到噪声影响的情况。具体来说,本文在 B0005、B0006、B0007 和 CS2-28 原始数据上分别叠加 SNR 为 20 dB 和 30 dB 的噪声信号,然后再次将本文模型的估计结果与其他 4 种模型得到的结果进行对比分析。

#### 3.1.1 基于 NASA 电池集的估计结果对比分析

NASA 的电池集的实际数据估计结果如图 9 所示。由图 9(a)一图 9(c)可知,DO-GRU 估计得到的 B0005、B0006、B0007 的 SOH 退化曲线均最接近其原始的 SOH 退化曲线。图 10(a)一图 10(c)分别为上述 5 种模型的 B0005、B0006、B0007 的估计结果误差分布箱线图,箱线图的高度越小,说明测试集的误差分布越集中,模型的稳定性越好。可以看出,

除了在 B0007 数据集下,RBF 模型的结果与本文提出的 DO-GRU 模型相接近以外,其他两种情况下,都是 DO-GRU 的高度最小,说明其有较好的稳定性。

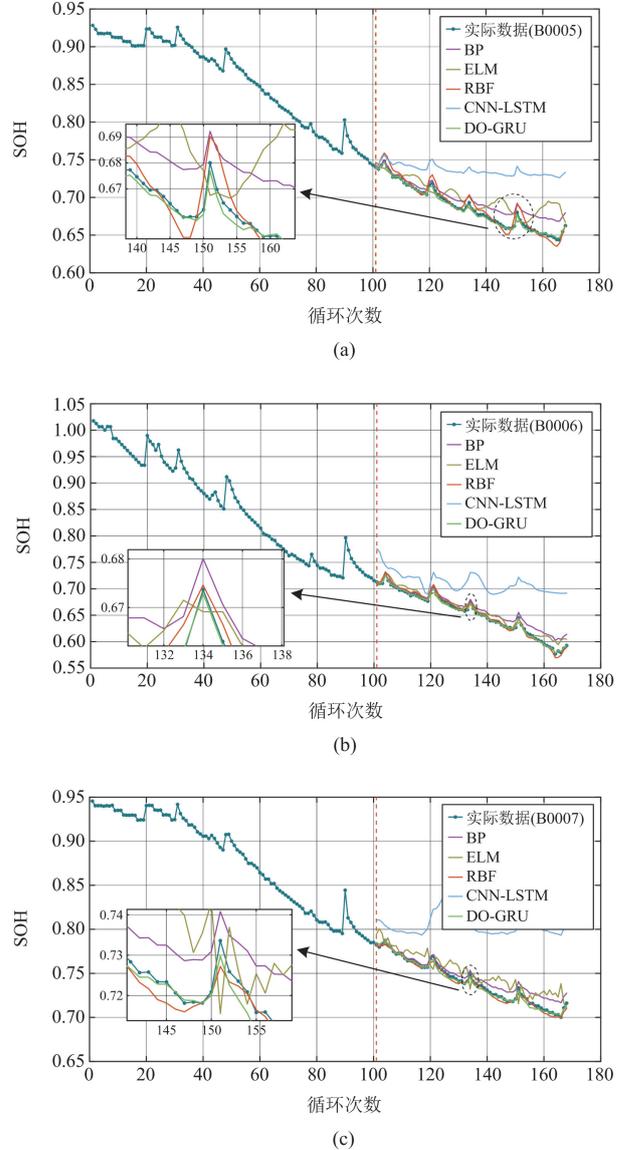
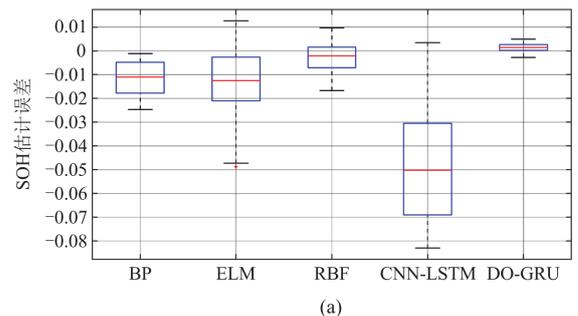
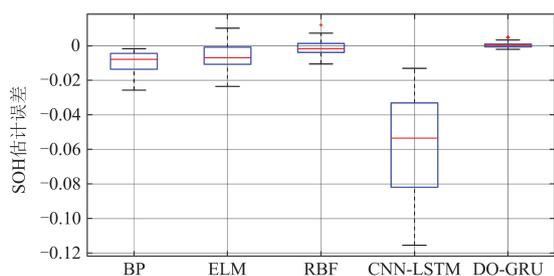


图 9 无噪声条件下的 SOH 估计结果

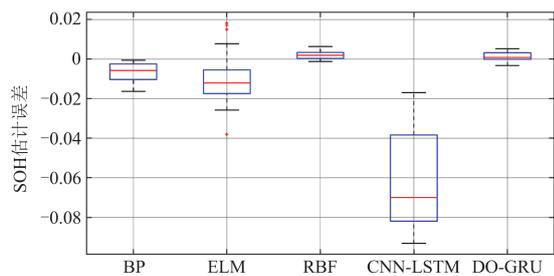
Fig. 9 SOH estimation results under non-noise condition



(a)



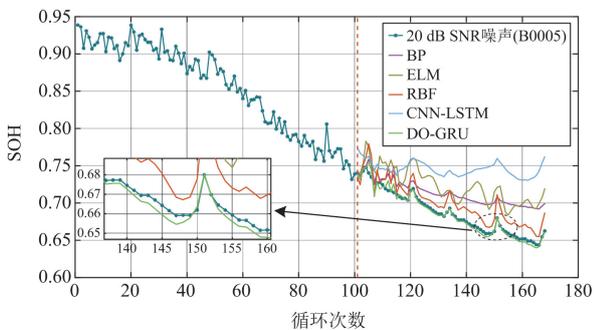
(b)



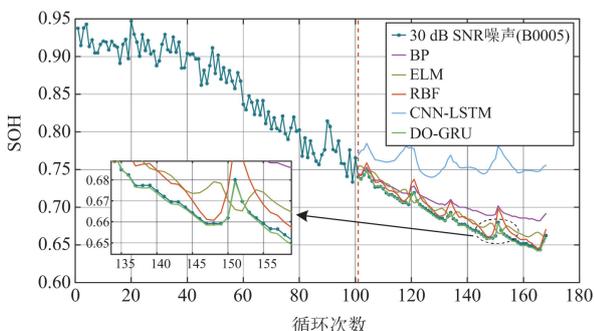
(c)

图 10 无噪声条件下的 SOH 估计误差分布结果  
Fig. 10 Error distribution of SOH estimation under non-noise condition

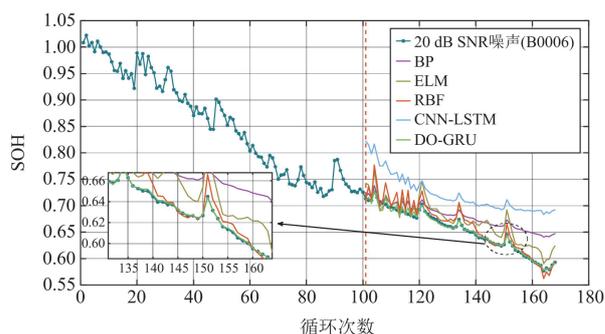
图 11 为 5 种模型分别对 B0005、B0006、B0007 在两种噪声环境下的 SOH 退化曲线估计结果。由图 11 可知, DO-GRU 的 SOH 退化曲线在 5 种模型中最贴合原始 SOH 退化曲线, 说明尽管训练数据受到不同程度噪声的影响, 但其依然能够实现精准的 SOH 估计。



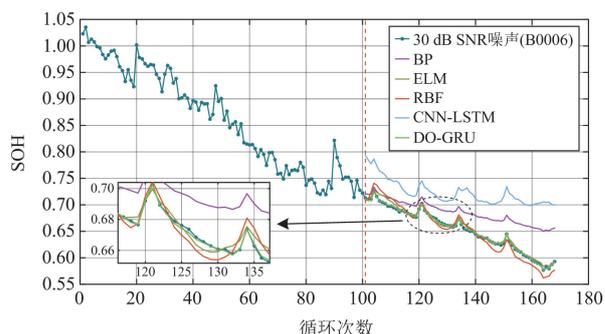
(a)



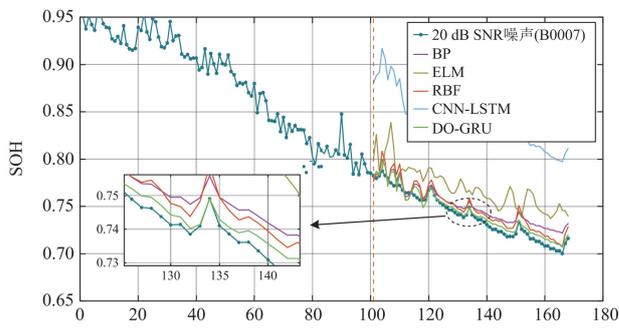
(b)



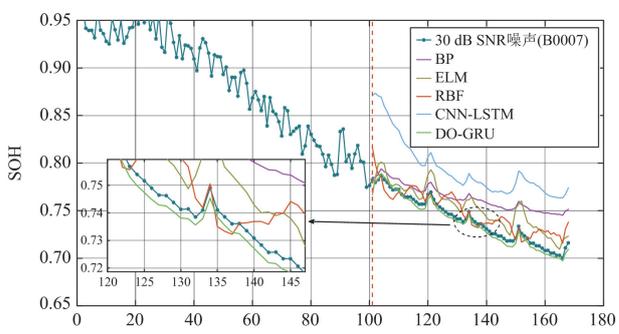
(c)



(d)



(e)

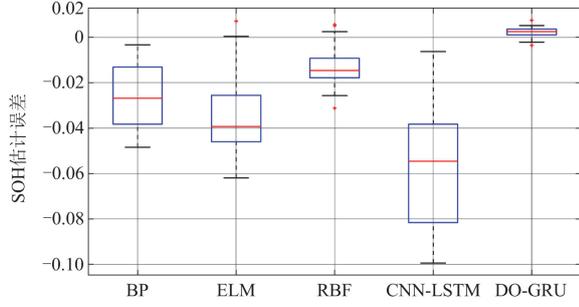


(f)

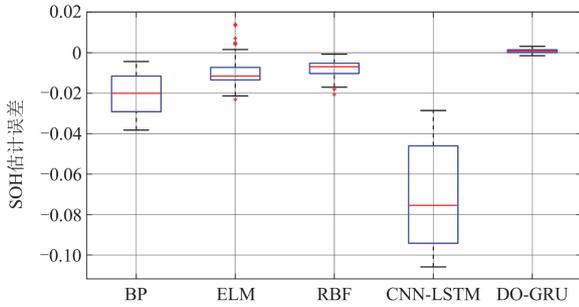
图 11 噪声条件下的 SOH 估计结果  
Fig. 11 SOH estimation results under noise condition

图 12 为 5 种模型在两种噪声情况下的估计结果误差分布箱线图。可以看出，尽管受到噪声影响，DO-GRU 估计模型依然最稳定。

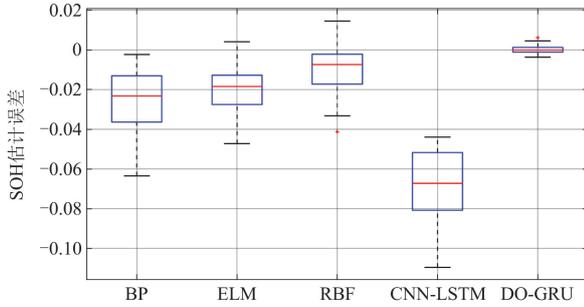
表 3 为估计结果的 MAE 量化数据。由表 3 可知，DO-GRU 模型在 B0005、B0006、B0007 下得到的 MAE 分别为 0.0017、0.0012 和 0.0018，在 5 种



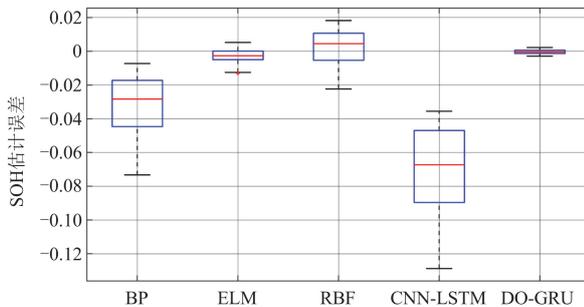
(a) 基于 20 dB SNR 噪声数据的 B0005 误差分布结果



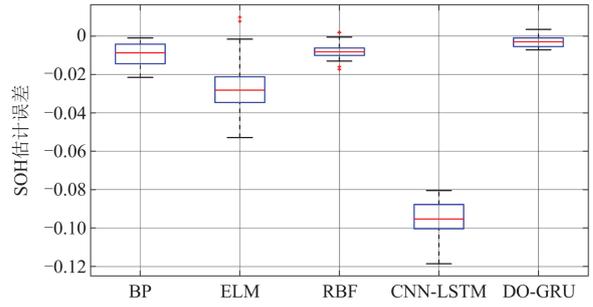
(b) 基于 30 dB SNR 噪声数据的 B0005 误差分布结果



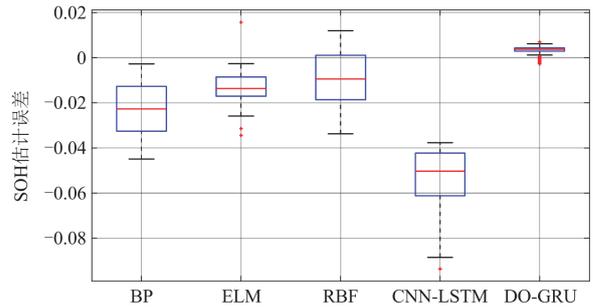
(c) 基于 20 dB SNR 噪声数据的 B0006 误差分布结果



(d) 基于 30 dB SNR 噪声数据的 B0006 误差分布结果



(e) 基于 20 dB SNR 噪声数据的 B0007 误差分布结果



(f) 基于 30 dB SNR 噪声数据的 B0007 误差分布结果

图 12 噪声条件下的 SOH 估计误差分布结果

Fig. 12 Error distribution of SOH estimation under noise condition

表 3 5 种模型在不同运行条件下的 SOH 估计 MAE 结果  
Table 3 SOH estimation MAE results with five models under different operation conditions

数据状态	模型	$e_{MAE}^{B0005}$	$e_{MAE}^{B0006}$	$e_{MAE}^{B0007}$
NASA 实际数据	BP	0.0115	0.0099	0.0066
	ELM	0.0159	0.0079	0.0128
	RBF	0.0054	0.0036	0.0021
	CNN-LSTM	0.0492	0.0586	0.0629
	DO-GRU	0.0017	0.0012	0.0018
加入 SNR 为 20 dB 的噪声	BP	0.0258	0.0270	0.0095
	ELM	0.0358	0.0198	0.0288
	RBF	0.0139	0.0116	0.0078
	CNN-LSTM	0.0581	0.0691	0.0950
	DO-GRU	0.0020	0.0014	0.0033
加入 SNR 为 30 dB 的噪声	BP	0.0206	0.0332	0.0232
	ELM	0.0111	0.0040	0.0139
	RBF	0.0078	0.0094	0.0115
	CNN-LSTM	0.0710	0.0699	0.0537
	DO-GRU	0.0022	0.0018	0.0036

模型中其数值均为最小，说明本文所提模型的估计性能优良。此外，通过与实际数据对比可知，受到噪声影响，5 种模型的  $e_{MAE}$  相较于无噪声情况下，数值有了一定的提高，说明噪声在一定程度上降低了 SOH 估计的精度，但 DO-GRU 的性能依然为最优。例如，在 SNR 为 20 dB 噪声信号下，B0005、

B0006、B0007 的  $e_{MAE}$  分别为 0.0020、0.0014 和 0.0033, 其数值均为 5 种模型中最小。

图 13 为 5 种模型在 B0005、B0006、B0007 下的估计结果 RMSE 柱状图。由图 13 可以看出, DO-GRU 模型在 3 种情况下的估计结果  $e_{RMSE}$  数值均为最小, 说明其性能最优。此外, 通过对比图 13(b)、图 13(c)可知, 噪声影响下得到的  $e_{RMSE}$  数值大于实际数据, 再次说明噪声影响会降低模型估计的精度。

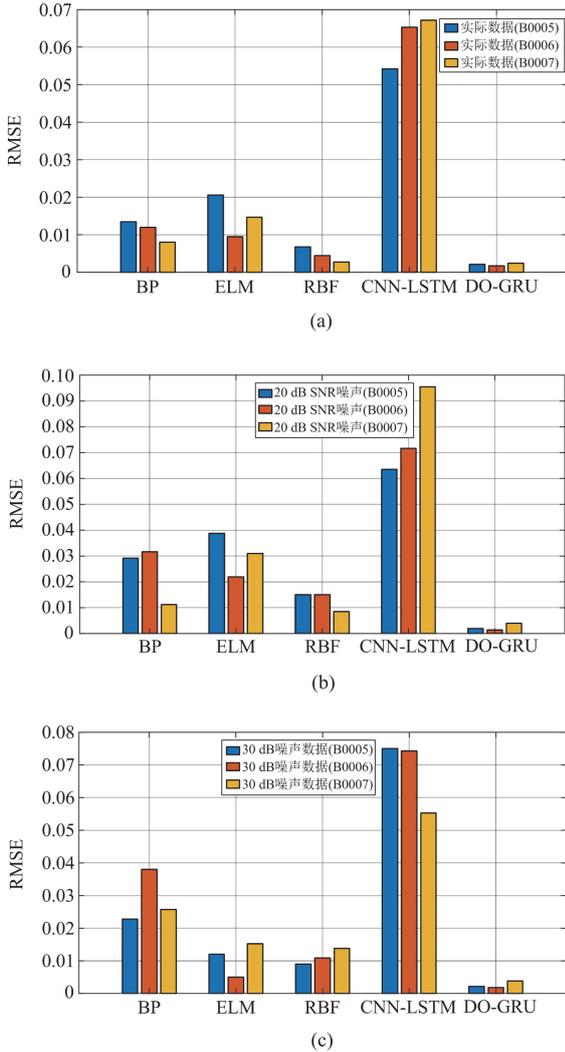


图 13 5 种模型在 B0005、B0006、B0007 下 SOH 估计的 RMSE 结果

Fig. 13 RMSE results of SOH estimation of B0005, B0006, and B0007 with five models

### 3.1.2 基于 CALCE 电池集的估计结果对比分析

图 14 中为 CALCE 电池集 CS2-38 在无噪声环境下的 SOH 估计结果, 其中, DO-GRU 模型得到的 SOH 退化曲线最接近原始的电池 SOH 退化曲线。

图 15 为 5 种模型的估计结果误差分布箱线图。由图 15 可知, DO-GRU 模型的误差分布区间明显窄于其他模型, 说明其具有较好的稳定性。

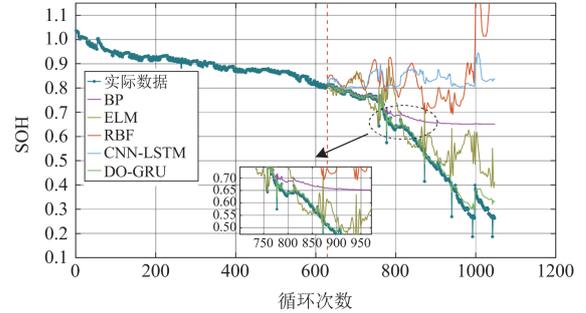


图 14 无噪声条件下的 SOH 估计结果

Fig. 14 SOH estimation results under non-noise condition

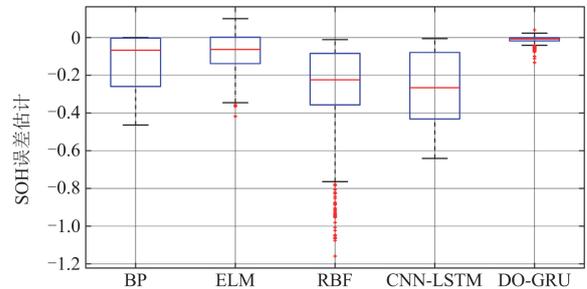
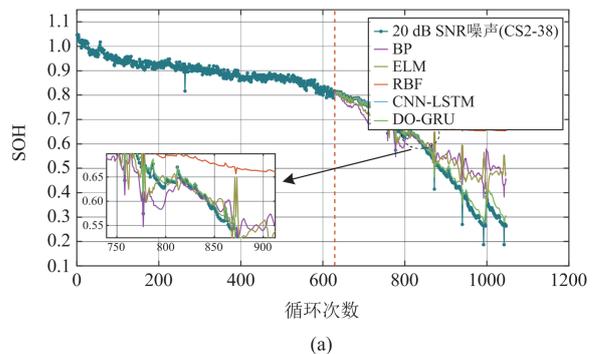


图 15 无噪声条件下的 SOH 估计误差分布结果

Fig. 15 Error distribution of SOH estimation under non-noise condition

图 16 为 5 种模型对 CACLE 电池集 CS2-38 在两种噪声环境下的 SOH 退化曲线估计结果。由图 16 可知, 对比各模型在不同噪声下的估计结果均与原始退化曲线有较大误差, 但 DO-GRU 模型的 SOH 退化曲线依然最贴合原始的 SOH 退化曲线, 说明尽管训练数据受到不同程度噪声的影响, 其依然能够实现精准的 SOH 估计。图 17 为 5 种模型在两种噪声情况下的估计结果误差分布箱线图, 可以看出, 尽管受噪声影响, DO-GRU 模型依然最稳定。



(a)

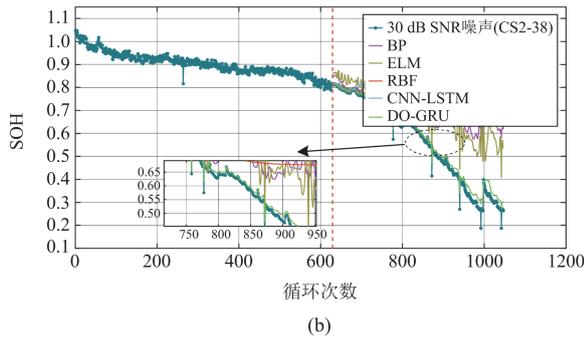
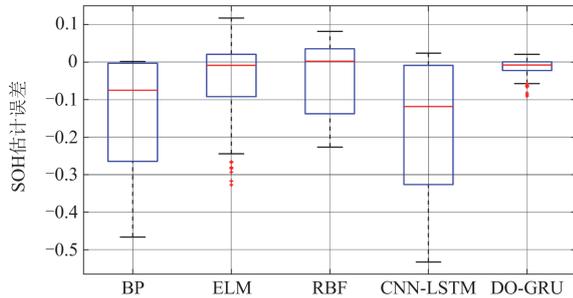
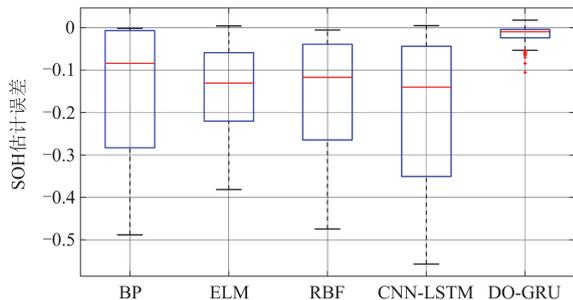


图 16 噪声条件下的 SOH 估计结果图

Fig. 16 SOH estimation results under noise condition



(a) 基于 20 dB SNR 噪声数据的 CS2-38 误差分布结果



(b) 基于 30 dB SNR 噪声数据的 CS2-38 误差分布结果

图 17 噪声条件下的 SOH 估计误差分布结果

Fig. 17 Error distribution of SOH estimation under noise condition

表 4 为实际数据集的估计结果  $e_{MAE}$  的量化数据, 此时 DO-GRU 模型基于 CALCE 电池集 CS2-38 获得的  $e_{MAE}$  为 0.0150, 在 5 种模型中最小, 说明 DO-GRU 模型的估计性能最优。在 SNR 为 20 dB 和 30 dB 噪声信号下, CALCE 电池集 CS2-38 使用 DO-GRU 模型获得的  $e_{MAE}$  分别为 0.0079 和 0.0145, 其值在各模型中也是最小。

### 3.2 RUL 估计结果分析

RUL 表示从当前电池状态衰减至电池寿命终止(end of life, EOL)时所经历的循环次数, 通常当 SOH 降至 70%~80%时, 电池的寿命被视为终止<sup>[26]</sup>。本文根据实际运行维护需求及各电池数据集的实际 SOH 退化曲线, 将 B0005、B0006、B0007 和 CS2-38

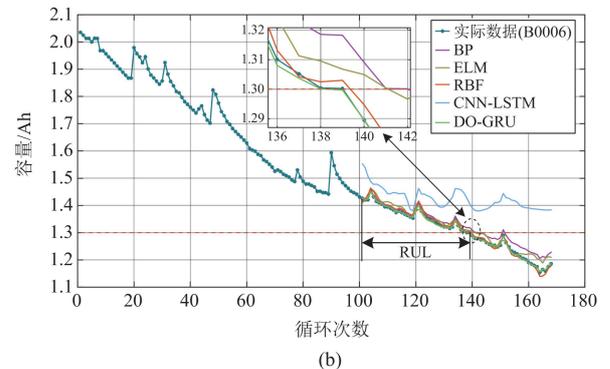
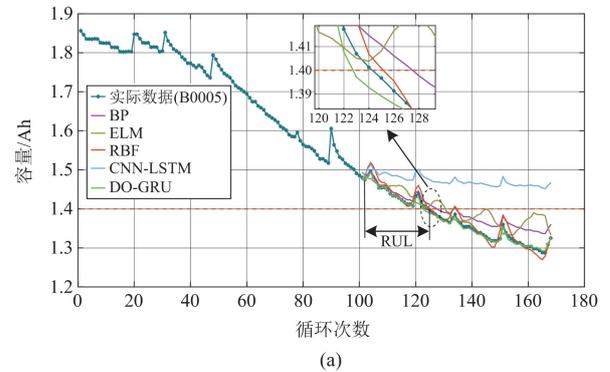
表 4 5 种方法在不同运行条件下的 SOH 估计 MAE 结果

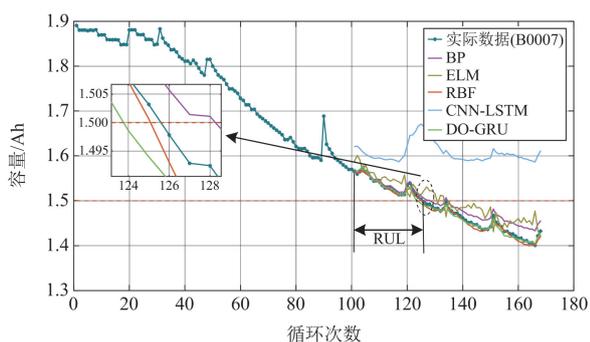
Table 4 Five methods of SOH estimation MAE results under different operation condition

数据状态	模型	$e_{MAE}^{CS2-38}$
CALCE 实际数据	BP	0.1340
	ELM	0.0953
	RBF	0.2860
	CNN-LSTM	0.2657
	DO-GRU	0.0150
加入 SNR 为 20 dB 的 噪声	BP	0.1506
	ELM	0.0153
	RBF	0.1335
	CNN-LSTM	0.2697
	DO-GRU	0.0079
加入 SNR 为 30 dB 的 噪声	BP	0.1449
	ELM	0.0555
	RBF	0.0562
	CNN-LSTM	0.2630
	DO-GRU	0.0145

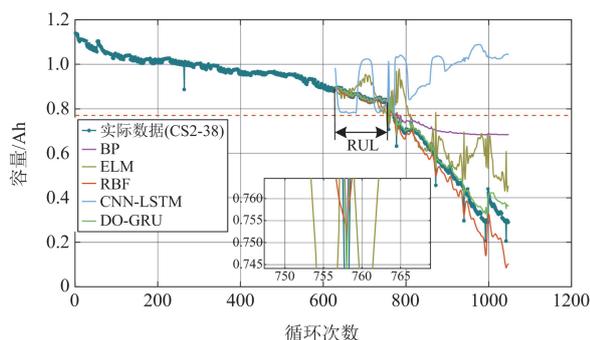
的 EOL 阈值分别设为 70%、65%、75%和 70%, 当电池 SOH 小于 EOL 阈值时, 即认为电池失效。

图 18 表示在训练集比例为 60%的情况下, B0005、B0006、B0007 和 CS2-38 在 5 种模型下得到的 RUL 估计结果, 从图中可以看出 DO-GRU 得到的估计值与真实值最为接近。





(c)



(d)

图 18 锂电池的 RUL 估计结果

Fig. 18 RUL estimation results for lithium batteries

表 5 为 B0005、B0006、B0007 和 CS2-38 经过各模型估计得到的失效时间和  $e_{AE}$  数值, 进一步量化了 RUL 模型的估计结果。其中, 符号 “-” 表示该预测模型未能预测到失效时刻。由表 5 可知, 对于 B0005、B0006、B0007 和 CS2-38, DO-GRU 模型估计得到的 AE 值分别为 1、0、0 和 0, 其性能在 5 种模型中最优。而其他 4 种模型中, 只有 RBF 模型在 B0007 和 CS2-38 下的性能与 DO-GRU 模型最接近, 其他模型均存在一定的误差, 其中 CNN-LSTM 模型的误差最大, 甚至出现了估计结果无法达到 EOL 阈值的情况。

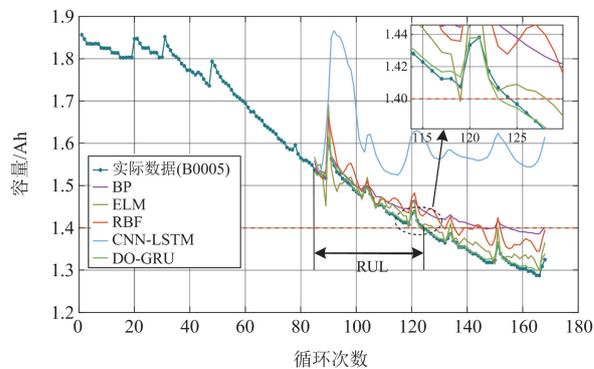
图 19 为 B0005、B0006、B0007 和 CS2-38 在训练集比例为 50% 的情况下得到的 RUL 估计结果。从图 19 可知, DO-GRU 模型的估计结果与真实值最接近。表 6 为各模型对 B0005、B0006、B0007 和 CS2-38 进行估计得到的失效时间和 AE 数值, 进一步量化 RUL 模型的估计结果。由表 6 可知, 对于 B0005、B0006、B0007 和 CS2-38, DO-GRU 模型估计得到的 AE 值分别为 1、1、0 和 0, 其性能在 5 种模型中最优。而其他 4 种模型中, 只有 ELM 模型在 B0007 情况下性能与 DO-GRU 模型最接近, 其他模型均存在一定的误差, 其中 CNN-LSTM 模型的预测误差波动最大, 甚至出现了估计结果无法

达到 EOL 阈值的情况。

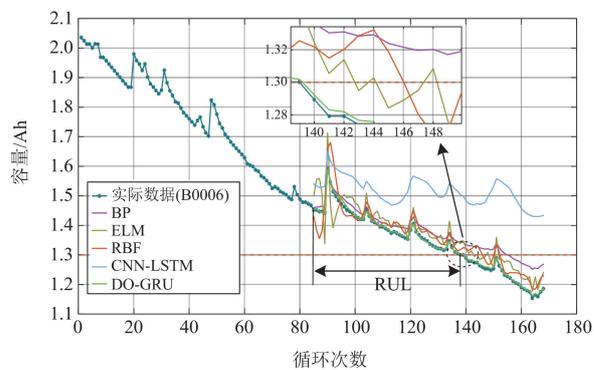
表 5 训练集比例为 60% 时 5 种方法估计得到的 RUL 结果

Table 5 RUL results estimated by five models with 60% training dataset

数据集	模型	EOL	起始点	RUL		$e_{AE}^{RUL}$
				真实值	预测值	
B0005	BP				27	4
	ELM				30	7
	RBF	124	101	23	25	2
	CNN-LSTM				—	—
	DO-GRU				22	1
B0006	BP				40	2
	ELM				40	2
	RBF	139	101	38	39	1
	CNN-LSTM				—	—
B0007	BP				27	2
	ELM				33	8
	RBF	126	101	25	25	0
	CNN-LSTM				—	—
CS2-38	BP				128	1
	ELM				125	4
	RBF	758	629	129	128	1
	CNN-LSTM				—	—
	DO-GRU				129	0



(a)



(b)

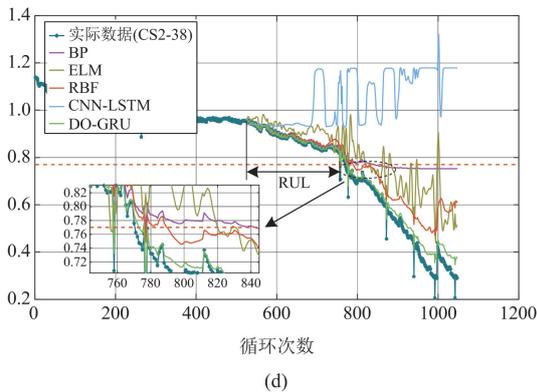
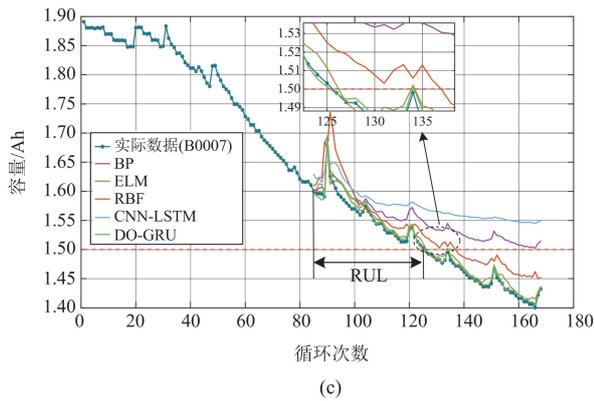


图 19 锂电池的 RUL 估计结果

Fig. 19 RUL estimation results for lithium batteries

表 6 训练集比例为 50% 时 5 种方法估计得到的 RUL 结果  
Table 6 RUL results estimated by five methods with 50% training dataset

数据集	模型	EOL	起始点	RUL 直实值	RUL 预测值	$e_{AE}^{RUL}$
B0005	BP	—	—	—	61	21
	ELM	—	—	—	34	5
	RBF	124	85	39	51	11
	CNN-LSTM	—	—	—	—	—
	DO-GRU	—	—	—	38	1
B0006	BP	—	—	—	70	16
	ELM	—	—	—	58	4
	RBF	139	85	54	62	8
	DO-GRU	—	—	—	55	1
B0007	BP	—	—	—	—	—
	ELM	—	—	—	42	1
	RBF	126	85	41	52	11
	DO-GRU	—	—	—	41	0
CS2-38	BP	—	—	—	318	85
	ELM	—	—	—	231	2
	RBF	758	525	233	265	32
	DO-GRU	—	—	—	233	0

### 3.3 对比分析

为进一步验证本文所提 DO-GRU 模型的稳定性与准确性，将其与文献[27-30]的模型进行比较。表 7、表 8 分别为 DO-GRU 模型的 SOH 和 RUL 预测结果与文献[27-30]模型的对比结果。从表 7、表 8 可知，DO-GRU 模型在 B0005、B0006 和 B0007 电池数据集上均优于文献[27-30]的模型，验证了 DO-GRU 模型在 SOH 和 RUL 预测方面的优势。

表 7 与文献[27-28]模型对比的 SOH 误差结果

Table 7 SOH error results compared with that of models in references [27-28]

数据集	模型	$e_{MAE}$
B0005	文献[27]	0.0027
	文献[28]	0.0028
	DO-GRU	0.0017
B0006	文献[27]	0.0074
	文献[28]	0.0044
	DO-GRU	0.0012
B0007	文献[27]	0.0038
	文献[28]	0.0030
	DO-GRU	0.0018

表 8 与文献[29-30]模型对比的 RUL 误差结果

Table 8 RUL error results compared with that of models in references [29-30]

数据集	模型	$e_{AE}$
B0005	文献[29]	6
	文献[30]	4
	DO-GRU	1
B0006	文献[29]	3
	文献[30]	2
	DO-GRU	0
B0007	文献[29]	7
	文献[30]	1
	DO-GRU	0

## 4 结论

本文提出了一种基于 ICEEMDAN-DO-GRU 的锂电池 SOH 和 RUL 估计模型。本文的创新点如下。

1) 利用 ICEEMDAN 对电池数据进行信号分解得到了 5 个与电池具有较强关联度的健康特征，该方法有效降低了电池特征提取的复杂度。

2) 利用 DO 算法对 GRU 网络的隐藏层神经元数目和初始学习率进行优化，有效提高了模型的估计性能。

3) 考虑不同 SNR 噪声信号对于估计结果的影响，研究了数据在噪声影响下，模型对于电池 SOH 和 RUL 估计的有效性和稳定性。

4) 将本文所提模型与其他4种典型模型在NASA和CALCE两种数据集下进行对比分析。实验结果表明, 本文所提模型估计精度高, 其得到的MAE最小值可达0.0012; 在噪声影响下依然能够准确地实现对SOH和RUL的估计, 且MAE最小值可达0.0014。

本文仅对单一运行工况下的电池进行了SOH和RUL估计验证, 在今后的研究中有必要对多种运行工况以及环境条件下的电池进行研究。

### 参考文献

- [1] 戴国洪, 张道涵, 彭思敏, 等. 人工智能在动力电池健康状态预估中的研究综述[J]. 机械工程学报, 2024, 60(4): 391-408.  
DAI Guohong, ZHANG Daohan, PENG Simin, et al. Overview of artificial intelligence in health prediction of power battery[J]. Journal of Mechanical Engineering, 2024, 60(4): 391-408.
- [2] REN J, MA J, WANG H, et al. A comprehensive review on research methods for lithium-ion battery of state of health estimation and end of life prediction: methods, properties, and prospects[J]. Protection and Control of Modern Power Systems, 2025, 10(3): 146-165.
- [3] 李卓昊, 石琼林, 王康丽, 等. 锂离子电池健康状态估计方法研究现状与展望[J]. 电力系统自动化, 2024, 48(20): 109-129.  
LI Zhuohao, SHI Qionglin, WANG Kangli, et al. Research status and prospects of state of health estimation methods for lithium-ion batteries[J]. Automation of Electric Power Systems, 2024, 48(20): 109-129.
- [4] YANG Bo, QIAN Yucun, LI Qiang, et al. Critical summary and perspectives on state-of-health of lithium-ion battery[J]. Renewable and Sustainable Energy Reviews, 2024, 190.
- [5] RAUF H, KHALID M, ARSHAD N. Machine learning in state of health and remaining useful life estimation: theoretical and technological development in battery degradation modelling[J]. Renewable and Sustainable Energy Reviews, 2022, 156.
- [6] YANG Bo, WANG Junting, CAO Pulin, et al. Classification, summarization and perspectives on state-of-charge estimation of lithium-ion batteries used in electric vehicles: a critical comprehensive survey[J]. Journal of Energy Storage, 2021, 39.
- [7] YU Xiaofang, MA Zhuang, WEN Jialin. Joint estimation of SOH and RUL for lithium batteries based on variable frequency and model integration[J]. International Journal of Electrochemical Science, 2024, 19.
- [8] 杨博, 钱玉村. 锂离子电池健康状态估计综述[J]. 昆明理工大学学报(自然科学版), 2024, 49(3): 147-165.  
YANG Bo, QIAN Yucun. A review on the state-of-health estimation for lithium-ion batteries[J]. Journal of Kunming University of Science and Technology (Natural Science), 2024, 49(3): 147-165.
- [9] 吴青峰, 杨艺涛, 刘立群, 等. 基于GA-SA-BP神经网络的锂电池健康状态估算方法[J]. 电力系统保护与控制, 2024, 52(19): 74-84.  
WU Qingfeng, YANG Yitao, LIU Liquan, et al. Lithium battery state of health estimation method based on a GA-SA-BP neural network[J]. Power System Protection and Control, 2024, 52(19): 74-84.
- [10] 吴铁洲, 朱俊超, 成雄帆, 等. 基于充电阶段数据与GWO-BiLSTM模型的锂电池SOH估计方法[J]. 电源技术, 2024, 48(11): 2184-2194.  
WU Tiezhou, ZHU Junchao, CHENG Xiongfán, et al. SOH estimation method of lithium-ion batteries based on charging stage data and GWO-BiLSTM model[J]. Power Technology, 2024, 48(11): 2184-2194.
- [11] 廖力, 肖廷奕, 吴铁洲, 等. 基于多健康特征融合的锂电池SOH和RUL预测[J]. 电源技术, 2023, 47(2): 193-198.  
LIAO Li, XIAO Tingyi, WU Tiezhou, et al. SOH and RUL prediction for lithium batteries based on fusion of multiple health features[J]. Chinese Journal of Power Sources, 2023, 47(2): 193-198.
- [12] 岳家辉, 夏向阳, 吕崇耿, 等. 计及健康特征信息量的锂离子电池健康状态与剩余寿命预测研究[J]. 电力系统保护与控制, 2023, 51(22): 74-87.  
YUE Jiahui, XIA Xiangyang, LÜ Chonggeng, et al. Research on the prediction of state of health and remaining useful life of lithium-ion batteries considering the amount of health factors information[J]. Power System Protection and Control, 2023, 51(22): 74-87.
- [13] 张梦迪, 刘洋, 陈健, 等. 基于ISSA-GPR的锂离子电池健康状态估计[J/OL]. 电源学报: 1-13[2025-05-11]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20231219.1345.010.html>  
ZHANG Mengdi, LIU Yang, CHEN Jian, et al. Estimation of health state of lithium-ion battery based on ISSA-GPR[J/OL]. Journal of Power Supply: 1-13[2025-05-11]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20231219.1345.010.html>
- [14] 晋殿卫, 顾则宇, 张志宏. 锂电池健康度和剩余寿命预测算法研究[J]. 电力系统保护与控制, 2023, 51(1): 122-130.  
JIN Dianwei, GU Zeyu, ZHANG Zhihong. Lithium battery health degree and residual life prediction algorithm[J]. Power System Protection and Control, 2023, 51(1): 122-130.
- [15] 毛玲, 温佳林, 赵晋斌, 等. 基于集成ELM的锂离子电池充电截止电压下的SOC和SOH联合估计[J]. 电力系统保护与控制, 2023, 51(11): 86-95.  
MAO Ling, WEN Jialin, ZHAO Jinbin, et al. Joint estimation of SOC and SOH at lithium-ion battery charging

- cut-off voltage based on an ensemble extreme learning machine[J]. *Power System Protection and Control*, 2023, 51(11): 86-95.
- [16] 夏向阳, 岳家辉, 曾小勇, 等. 基于状态相依的 RBF-ARX 模型的锂离子电池剩余容量估计方法[J]. *中国电机工程学报*, 2025, 45(2): 638-650.  
XIA Xiangyang, YUE Jiahui, ZENG Xiaoyong, et al. The remaining capacity estimation of battery based on state-dependent RBF-ARX model[J]. *Proceedings of the CSEE*, 2025, 45(2): 638-650.
- [17] 张慧颖, 王军华, 丁汀, 等. 基于多指标的 CNN-LSTM 锂电池 SOH 估计模型[J]. *电源技术*, 2023, 47(10): 1303-1307.  
ZHANG Huiying, WANG Junhua, DING Ting, et al. Multi-indicator based CNN-LSTM li-ion battery SOH estimation model[J]. *Chinese Journal of Power Sources*, 2023, 47(10): 1303-1307.
- [18] 方斯顿, 刘龙真, 孔赖强, 等. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计[J]. *电力系统自动化*, 2024, 48(4): 160-168.  
FANG Sidun, LIU Longzhen, KONG Laiqiang, et al. State-of-health estimation for lithium-ion batteries incorporating indirect health indicators based on bi-directional long short-term memory networks[J]. *Automation of Electric Power Systems*, 2024, 48(4): 160-168.
- [19] LIU Yunpeng, HOU Bo, AHMED M, et al. A hybrid deep learning approach for remaining useful life prediction of lithium-ion batteries based on discharging fragments[J]. *Applied Energy*, 2024, 358.
- [20] 李长云, 杨静雨, 连鸿松, 等. 基于 ICEEMDAN-IPSO-ELM 的硅油溶解气体浓度组合预测方法[J]. *高电压技术*, 2023, 49(9): 3898-3909.  
LI Changyun, YANG Jingyu, LIAN Hongsong, et al. Combined prediction method of dissolved gas concentration of silicone oil based on ICEEMDAN-IPSO-ELM[J]. *High Voltage Engineering*, 2023, 49(9): 3898-3909.
- [21] 李伟铭, 杨敬辉. 改进蒲公英优化算法的有限缓冲区流水车间调度[J]. *计算机系统应用*, 2024, 33(8): 240-249.  
LI Weiming, YANG Jinghui. Limited buffer flow workshop scheduling based on improved dandelion optimization algorithm[J]. *Computer Systems & Applications*, 2024, 33(8): 240-249.
- [22] 钱玉村, 杨博, 郑如意, 等. 基于经验模态分解-灰色关联度分析-蒲公英优化器改进 Elman 网络的锂离子电池健康状态估计[J]. *电网技术*, 2024, 48(9): 3695-3704.  
QIAN Yucun, YANG Bo, ZHENG Ruyi, et al. State-of-health estimation of lithium-ion batteries based on EMD-DO-Elman and GRA[J]. *Power System Technology*, 2024, 48(9): 3695-3704.
- [23] 彭自然, 王顺豪, 肖伸平, 等. 基于 KAIInformer 的电动汽车动力电池 SOC&SOH 估算[J/OL]. *电工技术学报*: 1-17[2025-03-17]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.241502>  
PENG Ziran, WANG Shunhao, XIAO Shenping, et al. State of charge and state of health estimation of electric vehicle power battery based on KAIInformer model[J/OL]. *Transactions of China Electrotechnical Society*: 1-17[2025-03-17]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.241502>
- [24] 孟安波, 陈顺, 王陈恩, 等. 基于混沌 CSO 优化时序注意力 GRU 模型的超短期风电功率预测[J]. *电网技术*, 2021, 45(12): 4692-4700.  
MENG Anbo, CHEN Shun, WANG Chenen, et al. Ultra-short-term wind power prediction based on chaotic CSO optimized temporal attention GRU model[J]. *Power System Technology*, 2021, 45(12): 4692-4700.
- [25] CHAE S, BAE S, OH K. State-of-health estimation and remaining useful life prediction of lithium-ion batteries using DNCNN-CNN[J]. *Journal of Energy Storage*, 2025, 106.
- [26] ZHANG Chaolong, ZHAO Shaishai, HE Yigang. An integrated method of the future capacity and RUL prediction for lithium-ion battery pack[J]. *IEEE Transactions on Vehicular Technology*, 2021, 71(3): 2601-2613.
- [27] HE Ye, BAI Wenyuan, WANG Lulu, et al. SOH estimation for lithium-ion batteries: an improved GPR optimization method based on the developed feature extraction[J]. *Journal of Energy Storage*, 2024, 83.
- [28] CHEN Liping, XIE Siqiang, LOPES ANTÓNIO M, et al. A new SOH estimation method for lithium-ion batteries based on model-data-fusion[J]. *Energy*, 2024, 286.
- [29] HU Xiaosong, YANG Xin, FENG Fei, et al. A particle filter and long short-term memory fusion technique for lithium-ion battery remaining useful life prediction[J]. *Journal of Dynamic Systems, Measurement, and Control*, 2021, 143(6).
- [30] CATELANI M, CIANI L, FANTACCI R, et al. Remaining useful life estimation for prognostics of lithium-ion batteries based on recurrent neural network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-11.

收稿日期: 2025-01-24; 修回日期: 2025-05-15

作者简介:

孙立明(1977—), 男, 博士研究生, 研究方向为电力系统、工业制造过程的先进控制系统与装置、电力系统生产过程数据的智能分析; E-mail: sunlm@139.com

余涛(1974—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为复杂电力系统的非线性控制理论、优化及机器学习。E-mail: taoyu1@scut.edu.cn

(编辑 石晋美)