

DOI:10.19651/j.cnki.emt.2417714

基于 IHOA-DELM 的锂离子电池 SOH 和 RUL 联合预测

曹旭 惠周利 杨明

(中北大学数学学院 太原 030051)

摘要: 准确预测锂离子电池的健康状态(SOH)和剩余使用寿命(RUL),对其安全稳定运行具有重要意义。本研究提出一种改进河马优化算法(IHOA)与深度极限学习机(DELM)相结合的新型算法。从锂电池充放电过程中提取了6个健康指标(HIs),通过Pearson相关分析保留了与容量相关性较高的5个HIs,接着用Hampel滤波去除特征数据中的异常值并归一化。最后建立电池SOH和RUL联和预测的DELM模型。此外,为了提高模型的预测效率,提出了IHOA对DELM的超参数进行优化。与传统的河马优化算法(HOA)相比,解决了传统河马算法在搜索效率、收敛速度和全局搜索等方面的局限性。基于CALCE锂电池数据集的实验仿真结果表明,IHOA-DELM算法的预测精度较高,SOH预测的RMSE值在1.21%~1.31%之间,MAE值在0.89%~0.95%之间,MAPE值在1.59%~1.93%之间;RUL预测的最大绝对误差(AE)值不超过3个周期,最小AE值只有1个周期。

关键词: 锂离子电池;健康状态;剩余使用寿命;IHOA;DELM

中图分类号: TN-9 文献标识码: A 国家标准学科分类代码: 110.87

Joint prediction of SOH and RUL for lithium-ion batteries based on IHOA-DELM

Cao Xu Hui Zhouli Yang Ming

(School of Mathematics, North University of China, Taiyuan 030051, China)

Abstract: Accurate prediction of the state of health (SOH) and remaining useful life (RUL) of lithium-ion batteries is of great significance for their safe and stable operation. In this paper, a novel Algorithm combining the improved hippopotamus optimization algorithm (IHOA) and deep extreme learning machine (DELM) is proposed. Six health indicators (HIs) were extracted from the charge and discharge process of lithium batteries, and the five HIs with high capacity correlation were retained by Pearson correlation analysis. Then, the outliers in the feature data were removed and normalized by Hampel filtering. Finally, the DELM model of SOH and RUL is established. In addition, In order to improve the prediction efficiency of the model, an IHOA is proposed to optimize the hyperparameters of DELM. Compared with the traditional hippopotamus optimization algorithm (HOA), it solves the limitations of the traditional hippopotamus algorithm in search efficiency, convergence speed and global search. The experimental simulation results based on CALCE lithium battery data set show that the prediction accuracy of IHOA-DELM algorithm is high, the root mean square error (RMSE) of SOH prediction of the proposed method ranges from 1.21%~1.31%, and the mean absolute error (MAE) value ranges from 0.89%~0.95%. The mean absolute percentage error (MAPE) was between 1.59%~1.93%. The maximum absolute error (AE) value predicted by RUL does not exceed 3 cycles, and the minimum absolute error value is only 1 cycle.

Keywords: lithium-ion battery; state of health; remaining useful life; IHOA; DELM

0 引言

近年来,能源和环境问题越来越突出,由锂离子电池驱

动的电动汽车在缓解这些问题方面显示出巨大的潜力和优势。与其他电池相比,锂离子电池具有高功率密度、高能量密度和长续航能力等优点^[1-2]。然而,由于操作环境的改变

和充放电过程中内部发生的化学反应导致其性能和容量永久性的下降^[3]。因此,准确的电池健康状态(state of health, SOH)和剩余使用寿命(remaining useful life, RUL)预测,对于保证电池全生命周期的安全稳定运行,避免灾难性事故的发生具有重要意义。

在目前的研究中,SOH 和 RUL 的预测主要通过两种方法进行,基于模型的方法和数据驱动的方法。基于模型的方法主要包括电化学模型(electrochemical model, EM)和等效电路模型(equivalent circuit model, ECM)^[4-6]。基于模型的方法虽然效果不错,但是模型往往复杂且需要获取可变参数,在分析过程中计算量大、测试周期长等问题,导致实际中往往难以建立完善的退化模型。

基于数据驱动的方法消除了锂离子电池内部复杂的化学变化,而是以影响电池性能退化的健康指标(health indicators, HIs)为参数,建立 HIs 和 SOH 之间的映射来预测 SOH^[7]。近年来,支持向量回归(support vector regression, SVR)^[8]、高斯过程回归(gaussian process regression, GPR)^[9]、极限学习机(extreme learning machine, ELM)^[10]和深度神经网络(deep neural network, DNN)^[11]等数据驱动方法在锂离子电池 SOH 和 RUL 估计中得到了广泛的应用。Ma 等^[12]基于广义极限学习机来进行锂离子电池的 SOH 估计。Bellomo 等^[13]提出了一种不同长度序列的深度学习回归模型用于锂离子电池 SOH 轨迹预测和 RUL 估计。李红磊等^[14]提出了一种基于 TCT-PSA 模型的锂离子电池 SOH 评估方法。深度极限学习机(deep extreme learning machine, DELM)将深度学习策略与极限学习机相结合^[15]。这种结合有助于探索数据中更深层次的关系。与传统深度学习模型相比,DELM 简化了模型的复杂性,在处理大规模高维数据时,训练速度更快,泛化能力更强。因此,在以上研究的基础上,本文选择 DELM 作为预测锂离子电池 SOH 和 RUL 的基本模型。然而如何选取最优参数确保模型预测的准确性问题亟待解决。

针对模型超参数的选取问题,很多研究者通过优化算法来寻找模型的最优超参数,来提高模型预测的准确性。Wu 等^[16]利用蝙蝠算法对 SVR 的超参数进行优化,并将优化后的 SVR 模型用于 SOH 的估计。Zhang 等^[17]提出了一种基于粒子群优化的 ELM 模型进行锂离子电池的 SOH 预测。陈新岗等^[18]提出了一种 ISSA-CNN-BiGRU-Attention 的锂电池 SOH 评估方法。郭喜峰等^[19]利用改进全局 ZOA 去优化 MVMD-SCN 来实现锂电池 SOH 估算。然而,传统的优化算法存在计算速度慢、容易产生局部最优等问题。针对这些问题,本文提出了一种改进的河马优化算法(improved hippopotamus optimization algorithm, IHOA),解决了传统河马优化算法(hippopotamus optimization algorithm, HOA)在搜索效率、收敛速度和全局搜索等方面的局限性,提高了模型的预测精度。

综上所述,本文提出了一种用于锂离子电池 SOH 和 RUL 联合估计的新型数据驱动模型 IHOA-DELM。首先,从电池数据中提取了反应电池容量衰减的 HIs。利用 Pearson 相关分析,保留了与电池容量退化密切相关的特征。使用 Hampel 滤波去除 HIs 噪声数据的干扰。归一化数据并划分成训练集和测试集。随后,针对传统河马优化算法固有的局限性,本文使用 3 种策略进行改进,解决了传统河马算法在搜索效率、收敛速度和全局搜索方面的局限性。利用训练集数据进行模型训练,在训练过程中基于 IHOA 得到 DELM 模型的最优超参数。最后,将测试集数据输入训练好的 IHOA-DELM 模型中进行电池 SOH 和 RUL 联合估计,并结合评价指标进行分析。结果表明,IHOA-DELM 模型对于 SOH 和 RUL 的联合预测具有较高的鲁棒性。

1 健康指标提取与数据预处理

1.1 CALCE 锂电池数据集

本文使用的锂离子电池老化数据源自 CALCE 的公开数据集,其中选取 CS2 系列的 CS2_35、CS2_36、CS2_37 和 CS2_38 四种电池作为实验对象,容量均为 1.1 Ah。这些电池均以恒定电流模式进行充电,充电速率为 0.5 C,当电池电压达到 4.2 V 时,再以恒定电压模式继续充电,直至充电电流降至 20 mA 充电结束。接着以 1 C 的恒流速率连续放电,直至电压达到 2.7 V。4 种电池的容量伴随循环次数增加表现出衰减趋势,其变化曲线如图 1 所示。当电池的可用容量下降至额定容量的 70% 时,被认为达到了寿命终点(end of life, EOL)。

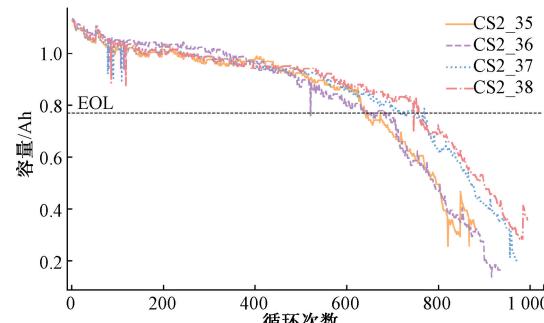


图 1 电池容量退化曲线

Fig. 1 Battery capacity degradation curve

1.2 健康指标提取

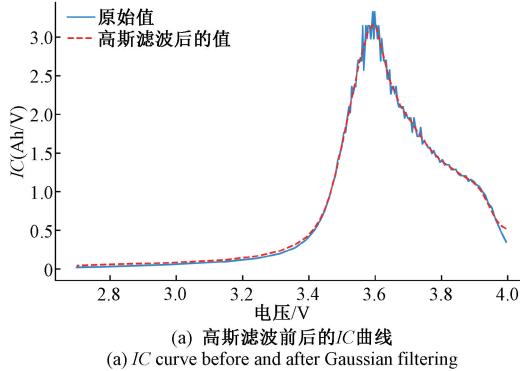
HIs 的提取对于锂电池 SOH 和 RUL 预测非常重要。常见的健康指标主要从电池的充放电电压变化率、充放电时间变化长度以及温度变化等方面进行描述。

本文从充放电电压、电流、时间、内阻 4 个方面提取了 4 种健康指标,从容量增量(increment capacity, IC)曲线中提取 2 种健康指标。包括电池恒流充电时间、恒压充电时间、内阻、最大峰值容量增量、最大峰值容量增量对应的电

压以及平均放电电压,分别命名为HI1-6。具体介绍如下:

1)恒流充电时间(constant current charging time, CCCT)为电池充电过程中恒定电流充电的时间。在恒流充电过程中,锂离子从阴极移动至阳极,电压升至4.2 V时停止恒流充电,避免电压过高导致极化和损坏电池结构。此时电池未完全充电,因此进入恒压充电阶段,随着充电容量增加,电池电压逐渐接近设定电压,为保持电压恒定,电流逐渐减小。随着充放电循环次数增加,恒流充电阶段电压变化率加快,充电时间缩短。

2)恒压充电时间(constant voltage charging time, CVCT)为电池充电过程中恒定电压充电的时间。锂离子电池的电阻特性有助于延长恒压充电的持续时间。温度显著影响锂电池的充电效率,导致CVCT相应增加。随着时间的推移,随着电池使用频率的增加和充电周期的积累,可能会发生内部损伤,如电极材料的结构改变和电解质耗尽。这些因素会导致电池充电效率下降,从而延长恒压充电周期。



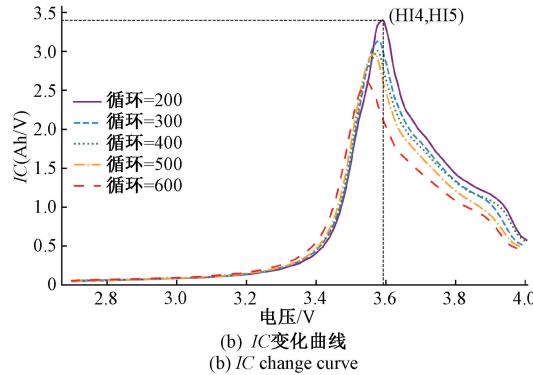
(a) 高斯滤波前后的IC曲线
(a) IC curve before and after Gaussian filtering

3)内阻为整个放电过程对应的平均内阻值。温度对内阻起着重要的影响作用,由于温度升高会加速电池内部的化学反应,导致内部材料膨胀和变形,最终导致内阻增加。

4)IC利用了锂离子电池中可在线测量的电压、电流等参数计算而得。这些变量提供了电池内部化学反应动态的直观可视化,将逐渐上升的电压转换为具有不同特征的容量增量曲线。最大峰值IC是基于IC曲线提取的。IC的计算公式为:

$$IC = \frac{dQ}{dV} = \frac{\Delta Q}{\Delta V} = I \frac{\Delta t}{V_t - V_{t-1}} = I \frac{\Delta t}{V_t - V_{t-1}} \quad (1)$$

式中: V_t 表示 t 时刻的放电电压。图2(a)中实线为CS2_35号电池在第100个放电循环的IC曲线图。为了减小噪声的影响,提高IC曲线的清晰度,采用高斯滤波算法对其进行过滤。过滤后的曲线清晰显示峰值位置,便于健康指标的提取。图2(b)为不同放电周期的IC变化趋势,最大峰值IC即为图中所标注点的纵坐标值。



(b) IC变化曲线
(b) IC change curve

图2 IC曲线

Fig. 2 IC curve

5)最大峰值IC对应的电压为图2(b)中所标注点的横坐标值。

6)平均放电电压为放电过程中所有时间点测量电压的平均值。随着充放电次数的增加,电池内部的电阻逐渐增加。内阻的增加会直接导致电池在放电时产生更多的电压降,造成放电电压下降。而且随着充放电循环次数的增加,锂离子电池的有效容量会逐渐减少。容量的减少意味着同样的放电电流下,电池的电压会更早下降,从而降低了放电时的平均电压。

因此,以上6种特征作为HIs是合理的。图3给出了选取的四种电池的6组HIs的提取结果,从整体趋势上可以看出6组HIs的变化趋势与图1中电池的容量退化趋势呈明显的正相关或负相关。

1.3 数据处理

1)Pearson相关性分析

本文利用Pearson相关系数来量化健康特征与实际电池容量之间的关系。其计算过程如式(2)所示。

$$\rho_{x,y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (2)$$

式中: $\rho_{x,y}$ 表示变量 X 和变量 Y 之间的相关系数, X_i 和 Y_i 分别表示健康特征样本和电池的实际容量, \bar{X} 和 \bar{Y} 分别为两者的样本均值。Pearson相关分析的结果如图4所示,从图中可以看出HI1, HI3, HI4, HI5, HI6这5个HIs与容量的相关性较强,所以选取这5个HIs为输入特征。

2)Hampel滤波器

电池数据集中提取的健康指标数据会受到异常值干扰。为解决这一问题,本研究采用Hampel滤波器^[20]来解决这一问题。假设给定一个一维特征序列 $x = \{x_1, x_2, \dots, x_n\}$,和长度为 $2k+1$ 的滑动窗口,则窗口内样本的中位数和标准差估计如式(3)和(4)所示。

$$m_i = median(x_{i-k}, x_{i-k+1}, \dots, x_i, \dots, x_{i+k-1}, x_k) \quad (3)$$

$$\sigma_i = 1.4286 \times median(|x_{i-k} - m_i|, \dots, |x_{i+k} - m_i|) \quad (4)$$

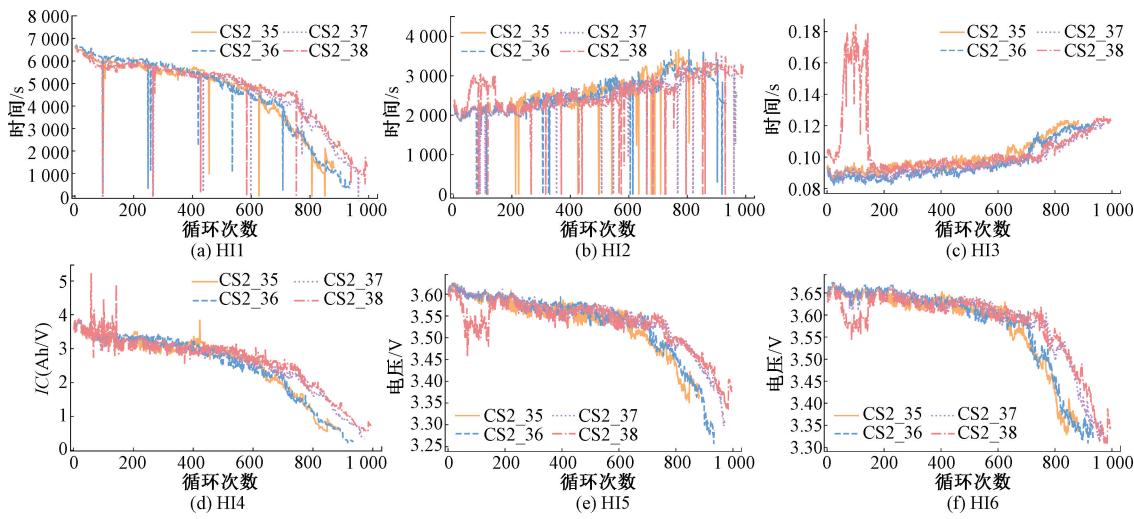


图 3 健康指标提取结果
Fig. 3 Health index extraction results

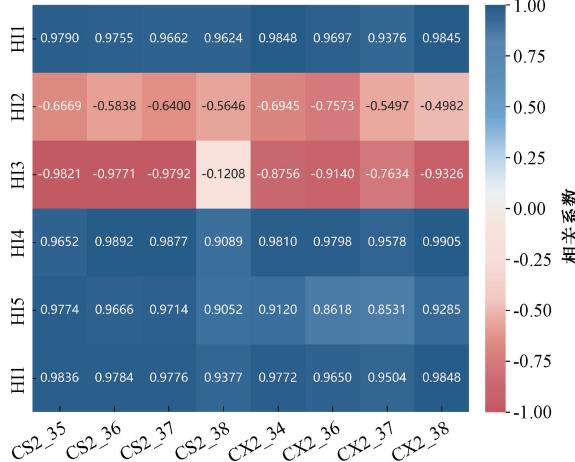


图 4 HIs 与电池容量的相关系数图
Fig. 4 Graph of correlation coefficient between HIs and battery capacity

$y_j = \begin{cases} x_j, & |x_j - m_i| \leq 3\sigma_i \\ m_i, & \text{其他} \end{cases}, j = 1, 2, \dots, 2k + 1$

(5)

式中: y_j 为该窗口滤波后的数据。

在 Hampel 滤波之后, 要对得到的特征数据集进行归一化处理。这样做可以避免某些特征对模型训练产生不必要的影响。归一化的公式为:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

式中: x 和 x^* 分别为归一化前后的数据, x_{\max} 和 x_{\min} 分别为该组数据中的最大值和最小值。

2 预测方法

2.1 深度极限学习机模型

1) 极限学习机

ELM 是一个单隐层前馈神经网络。结构如图 5 所示。

其特点是隐藏层的输入权重和阈值在训练过程中随机生成, 具有较强的泛化能力和较快的学习速度。隐层神经元输出如式(7)所示。

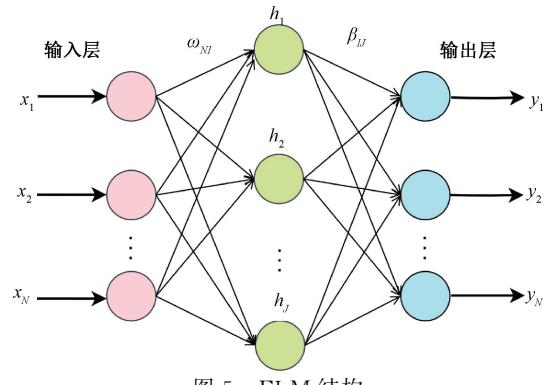


图 5 ELM 结构
Fig. 5 ELM structure

$$\mathbf{H} = g(\boldsymbol{\omega} \mathbf{X} + \mathbf{B}) \quad (7)$$

式中: g 为激活函数, $\boldsymbol{\omega}$ 是输入层节点到隐藏层节点的输入权重矩阵。 \mathbf{B} 为隐藏层的阈值矩阵。隐藏层的输出权重 $\boldsymbol{\beta}$ 可利用最小二乘法快速求解, 求解公式如式(8)所示。

$$\boldsymbol{\beta} = \left(\frac{1}{C} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \mathbf{Y} \quad (8)$$

式中: C 为正则化系数, \mathbf{Y} 为真实输出。

2) 深度极限学习机

自动编码器(autoencoder, AE)在经过无监督的训练后, 可以将输入 X 复制到输出 Y 。将自动编码器的思想融入 ELM 中, 可构建出 DELM 的基本单元——ELM-AE。为了获得更好的泛化性能, ELM-AE 的隐藏层权重和偏置被选择为正交, 如式(9)所示。

$$\boldsymbol{\omega}^T \boldsymbol{\omega} = \mathbf{I}, \mathbf{B}^T \mathbf{B} = \mathbf{I} \quad (9)$$

式中: $\boldsymbol{\omega}$ 和 \mathbf{B} 为正交后的权重矩阵和偏置矩阵。同 ELM 一样, ELM-AE 的输出权重 $\boldsymbol{\beta}$ 也可由式(8)计算得出。将

其转置后作为 ELM 的隐藏层权重矩阵。

DELM 的结构如图 6 所示。它由多个 ELM-AE 组件

耦合在一起组成,通过构建深层网络结构更好地捕捉数据的映射关系,能够处理复杂的非线性问题。

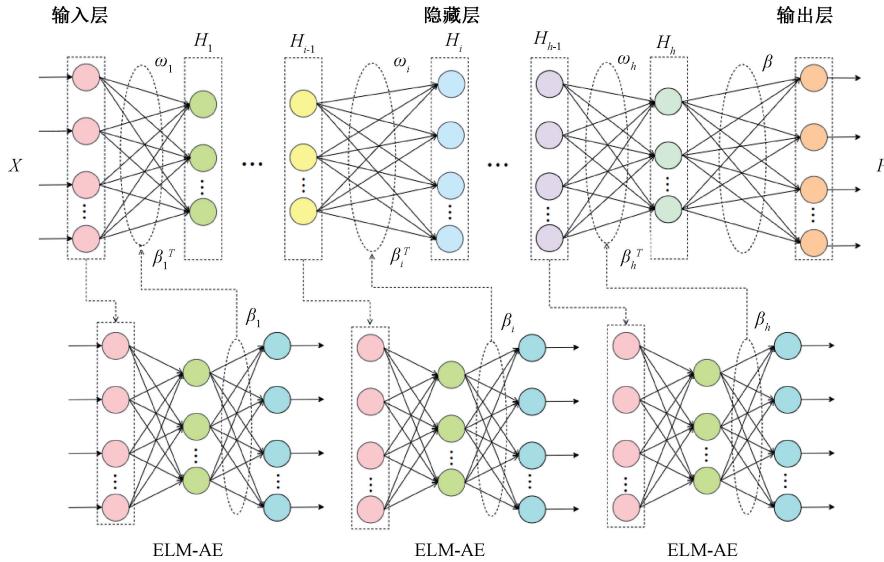


图 6 DELM 结构

Fig. 6 DELM structure

2.2 河马优化算法

HOA^[21]是从观察到的河马的 3 种突出行为中汲取灵感而构思的。

1) 种群初始化

与传统的优化算法类似, HOA 的初始解的生成公式为:

$$x_{ij} = lb_j + r(ub_j - lb_j), \quad i = 1, 2, \dots, N, j = 1, 2, \dots, m \quad (10)$$

式中: x_{ij} 代表第 i 个候选解的第 j 个决策变量的值, r 是 $0 \sim 1$ 内的随机数, lb_j 和 ub_j 分别表示第 j 个决策变量的下界和上界, N 表示种群规模, m 表示问题中决策变量的个数。

2) 河马在河流或池塘中的位置更新

河马为群体动物, 式(11)为河马群中的雄性河马在河流或池塘中的位置更新公式。

$$\begin{cases} \mathbf{X}_i^{HM}: x_{ij}^{HM} = x_{ij} + y_1(D_{hippo} - I_1 x_{ij}) \\ i = 1, 2, \dots, \left[\frac{N}{2} \right], j = 1, 2, \dots, m \end{cases} \quad (11)$$

式中: \mathbf{X}_i^{HM} 表示雄性河马的新位置, y_1 是 $0 \sim 1$ 之间的随机数, D_{hippo} 表示当前迭代次数的河马种群中的最优河马, I_1 是 $1 \sim 2$ 之间的整数。

$$h = \{I_1 \times \mathbf{r}_1 + (\sim Q_1), 2\mathbf{r}_2 - 1, \mathbf{r}_3, I_2 \times \mathbf{r}_4 + (\sim Q_2), r_5\} \quad (12)$$

式中: $\mathbf{r}_{1, \dots, 4}$ 是 $0 \sim 1$ 之间的随机向量, r_5 是 $0 \sim 1$ 之间的随机数, I_1 和 I_2 是 1 或者 2。 Q_1 和 Q_2 是 0 或者 1, \sim 是取反的意思。河马群中的雌性或幼年河马的位置更新公式如式(13)所示。

$$\begin{cases} \mathbf{X}_i^{FB}: x_{ij}^{FB} = \{x_{ij} + h_1(D_{hippo} - I_2 \cdot MG_i), e^{-\frac{t}{T}} > 0.6 \\ E, \text{ 其他} \\ i = 1, 2, \dots, \left[\frac{N}{2} \right], j = 1, 2, \dots, m \end{cases} \quad (13)$$

$$E = \begin{cases} x_{ij} + h_2(MG_i - D_{hippo}), r_6 > 0.5 \\ lb_j + r_7(ub_j - lb_j), \text{ 其他} \end{cases} \quad (14)$$

式中: \mathbf{X}_i^{FBi} 为雌性或幼年河马在兽群中的新位置, t 为当前迭代次数, T 为最大迭代次数。 r_6 为 $0 \sim 1$ 的随机数, h_1 和 h_2 是式(12)中 5 种情况中随机的一种。 r_7 是 $0 \sim 1$ 的随机数。

3) 河马防御捕食者

河马在面对捕食者采用的主要防御策略是迅速转向捕食者, 并发出响亮的叫声, 以阻止捕食者靠近它们。此时河马的位置更新公式为:

$$\begin{cases} \mathbf{X}_i^{HR}: x_{ij}^{HR} = \begin{cases} A + B\left(\frac{1}{D}\right), F^p < F_i \\ A + B\left(\frac{1}{2D + r_9}\right), F^p \geqslant F_i \end{cases} \\ i = \left[\frac{N}{2} \right] + 1, \left[\frac{N}{2} \right] + 2, \dots, N, j = 1, 2, \dots, m \end{cases} \quad (15)$$

$$A = \mathbf{RL} \oplus P_j \quad (16)$$

$$B = \frac{f}{c - d \cdot \cos(2\pi g)} \quad (17)$$

式中: F_i 和 F^p 分别为河马和捕食者的适应度, \mathbf{X}_i^{HR} 是河马面对捕食者的位置。 A 和 B 分别如式(16)和(17), \mathbf{RL} 是一个具有 $Lévy$ 分布的随机向量, \oplus 是内积的意思。 P_j 是捕

食者位置第 j 个决策变量的值, 其位置生成公式同式(10)。 f 是一个 $2 \sim 4$ 的随机数, c 是一个 $1 \sim 1.5$ 的随机数, d 是一个 $2 \sim 3$ 的随机数, g 是一个 $-1 \sim 1$ 的随机数, $\bar{D} = |P_j - x_{ij}|$ 为第 i 只河马到捕食者的距离, r_2 是一个一维的随机向量。

4) 河马躲避捕食者

当河马遇到一群捕食者且无法用防御行为击退捕食者时。在这种情况下, 河马试图离开该区域, 以避免捕食者的伤害。位置更新公式为:

$$\begin{cases} \mathbf{X}_i^{HE}: X_{ij}^{HE} = x_{ij} + r_{10} \left(\frac{lb_j}{t} + s_1 \left(\frac{ub_j}{t} - \frac{lb_j}{t} \right) \right) \\ i = 1, 2, \dots, N, j = 1, 2, \dots, m \end{cases} \quad (18)$$

式中: X_i^{HE} 为河马找到的最近安全位置, t 表示当前迭代次数, T 表示最大迭代次数。 r_{10} 是一个 $0 \sim 1$ 之间的随机数, s_1 是式(19)中 3 种情况中随机的一种。

$$s_1 = \{2r_{11} - 1, r_{12}, r_{13}\} \quad (19)$$

式中: r_{11} 为 $0 \sim 1$ 之间的随机向量, r_{12} 是一个服从标准正态分布的随机数, r_{13} 是一个 $0 \sim 1$ 之间的随机数。

2.3 改进的河马优化算法

1) Latin Hypercube 采样

Latin Hypercube 采样 (Latin Hypercube sampling, LHS)^[22] 是一种在多维空间中进行均匀采样的方法, 用于在每个参数空间中生成一组尽可能均匀且尽可能少重复的确定维度和区间。具体步骤如下:

(1) 假设有 n 个输入变量, 每个变量的取值区间为 $[a_i, b_i] (i = 1, 2, \dots, n)$ 。

(2) 将每个区间 $[a_i, b_i]$ 均匀地划分为 N (河马数) 个子区间。在每个区间随机选取一个点。

(3) 最后将每个变量的样本点随机且不重复组合, 形成一个 n 维的向量。具体公式如下:

$$\mathbf{X}_i^{new} = (ub - lb) \cdot lhs(m) + lb \quad (20)$$

式中: \mathbf{X}_i^{new} 为第 i 个河马新的初始化位置, ub 和 lb 分别为所有决策变量的上界和下界, $lhs(m)$ 为基于 LHS 的函数, 其返回值为一个 1 行 m 列的向量, m 为决策变量的个数。LHS 的抽样比随机分布更均匀。因此, 使用 LHS 的种群初始化算法有助于避免种群在初始化阶段陷入困境。

2) 元启发式算法 Jaya

Jaya 算法是 Rao 等^[23] 提出的一种元启发式算法, 它利用持续改进的思想, 不断接近最优个体, 同时远离最差个体, 从而不断提高解的质量。本文根据这一思想更新河马位置。

$$\begin{cases} \mathbf{X}_i(t+1) = \mathbf{X}_i(t) + r_1 \mathbf{a}_1 - r_2 \mathbf{a}_2 \\ \mathbf{a}_1 = (\mathbf{X}_{best}(t) - |\mathbf{X}_i(t)|), \mathbf{a}_2 = (\mathbf{X}_{worst}(t) - |\mathbf{X}_i(t)|) \end{cases} \quad (21)$$

式中: $\mathbf{X}_i(t)$ 为第 t 次迭代第 i 个河马的位置, $\mathbf{X}_{best}(t)$ 和 $\mathbf{X}_{worst}(t)$ 分别为第 t 次迭代中最优和最劣的河马位置, r_1 和

r_2 均为 $0 \sim 1$ 的随机数。

3) 平稳探索

平稳探索^[24] 该方法包括无序维数采样、随机交叉和序列突变。在 HOA 算法的第 4 阶段, 这 3 种机制相辅相成, 提高了 HOA 的探索能力。

无序维数采样将维度选择视为一个抽样过程。采样率决定了涉及的维度数量, 这些涉及的维度是基于采样率随机抽样选择的, 而其他未选择的维度是静态的。无序维数采样减少了接近最佳目标的维度, 从而防止了总体稀疏度的下降。并促进编程的向量化, 以减少运行时间。其采样率的计算公式为:

$$rate = ceil \left(\max \left\{ \frac{t}{maxIter}, 0.1 \cdot e \right\} \times dim \right) \quad (22)$$

式中: $rate$ 为采样率, t 为当前迭代次数, $maxIter$ 为最大迭代次数, dim 为决策变量个数, $ceil()$ 函数将数字向上取整。

随机交叉可以通过随机选择个体来提高探索能力。随机交叉表示为:

$$\mathbf{X}_i(t+1) = \mathbf{X}_{r1} - (\mathbf{X}_{r3} - \mathbf{X}_{r2}), r1, r2, r3 \neq i \quad (23)$$

式中: $r1, r2, r3$ 是随机选择的索引。

随机交叉依赖于两个随机个体来决定探索空间的范围, 当半径太小时, 它可能会过早地陷入局部最优。因此, 提出了序列突变来解决这个问题。探索两个连续个体之间的空间可以防止后代过于靠近上一代, 减缓搜索空间的缩小。因此, 序列突变和随机交叉相辅相成, 提高了搜索能力。序列突变表示为:

$$\mathbf{X}_i(t+1) = \frac{\mathbf{X}_i(t) + \mathbf{X}_{i-1}(t)}{2} \quad (24)$$

式中: $\mathbf{X}_i(t)$ 是第 t 次迭代的第 i 个个体, $\mathbf{X}_{i-1}(t)$ 是 $\mathbf{X}_i(t)$ 的前 1 个个体, $\mathbf{X}_i(t+1)$ 是第 i 个个体新的位置。

IHOA 的流程图如图 7 所示。

2.4 IHOA-DELM 模型

结合上文所提模型结构, 本文提出的基于 IHOA-DEKM 的锂离子电池 SOH 和 RUL 联和预测模型的完整流程如图 8 所示。该模型的所有步骤均有 Python 语言实现, 步骤描述如下:

1) 特征提取。从充放电数据和高斯滤波处理之后的 IC 曲线中提取了与电池容量退化相关的 6 个健康指标。

2) 特征处理。采用 Pearson 相关系数保留了与电池容量相关性较高的 5 个健康指标。用 Hampel 滤波处理保留的健康指标数据, 去除异常值的干扰。最后将特征数据归一化并划分为 50% 训练集和 50% 测试集。

3) 模型训练。为了解决传统河马算法在搜索效率、收敛速度和全局搜索等方面的局限性。使用 3 种策略去改进河马优化算法, 具体改进细节如图 7 所示。利用 IHOA 优化 DELM 的超参数, 包括权重和阈值。这里设置 DELM 的隐层为 3, 神经元个数分别为 25、15 和 5, 权重的上下限

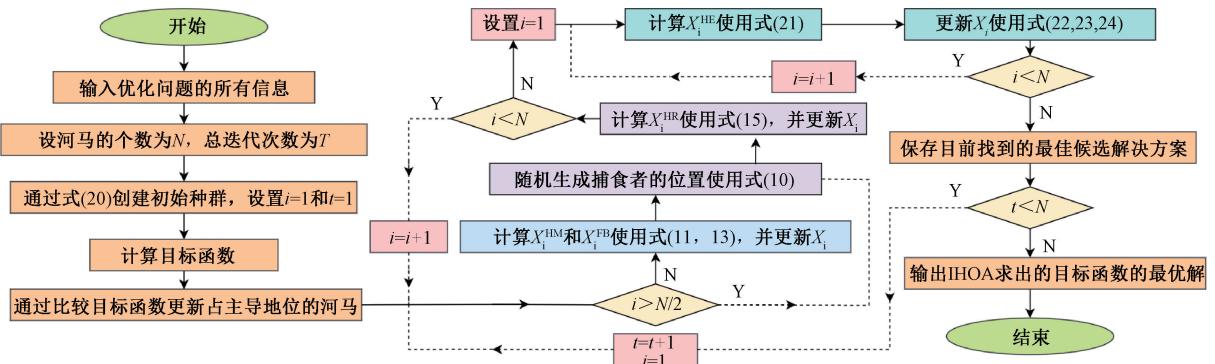


Fig. 7 Flow chart of improved hippopotamus optimization algorithm

为 1 和 -1，阈值的上下限为 2 和 -2。若更新后的权重和阈值结果超出取值范围，那么大于上限则用上限替代，小

于下限则用下限替代。选取模型预测的均方误差作为适应度函数，并将训练集输入模型进行训练。

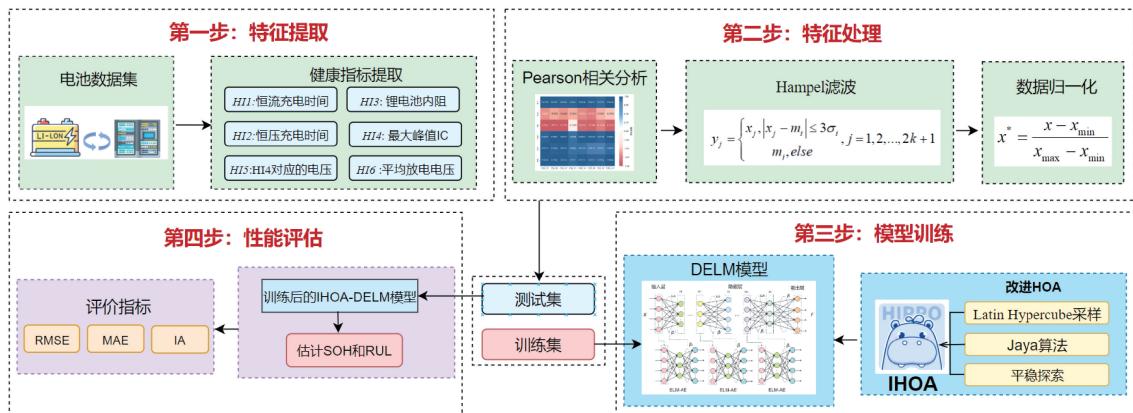


Fig. 8 IHOA-DELM algorithm jointly predicts SOH and RUL flow charts

4) 性能评估。将测试集输入训练好的模型进行 SOH 和 RUL 的预测，结合评价指标验证所提模型与其他模型估计锂离子电池 SOH 和 RUL 的准确性。

3 数据结果分析

3.1 评价指标

通过均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和平均百分比误差(mean absolute percentage error, MAPE)对本文模型预测结果进行评价。3 个评价指标如下：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (25)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (26)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (27)$$

式中： \hat{y}_i 和 y_i 分别为电池容量的预测值和观测值， n 为电池预测的总循环数。这 3 种评价指标值越小，模型的估计

越准确、越稳定，预测效果越好。

3.2 预测结果分析

锂离子电池的 SOH 和 RUL 通常被用作评估当前退化程度的指标。在大多数情况下，SOH 是用容量来量化的，计算公式为：

$$SOH = \frac{Q_i}{Q_0} \quad (28)$$

式中： Q_i 是第 i 次循环时的容量， Q_0 是该电池的额定容量。而 RUL 通常表示从当前电池 SOH 到电池使用 EOL 的剩余使用周期数。

为了验证 IHOA-DELM 模型预测性能的优越性，使用 DELM、WOA-DELM、PSO-DELM 和 HOA-DELM 来与本文提出的 IHOA-DELM 模型进行比较。使用 4 种电池的前 50% 数据作为训练集，后 50% 的数据作为测试集。SOH 和 RUL 预测结果如图 9 所示，SOH 预测误差如图 10 所示。从图中可以看出，HOA-DELM 模型在预测能力的准确性上要优于 DELM、WOA-DELM 和 PSO-DELM 这 3 种模型，这充分体现了 HOA 在优化效果方面的优势。而 IHOA-DELM 模型在预测能力的准确性和稳

健性上还要优于 HOA-DELM 模型。说明 IHOA 解决了传统 HOA 在搜索效率、收敛速度和全局搜索等方面的问题。

而且, IHOA-DELM 模型能够更准确地预测某些突变区域的容量变化幅度, 并捕获大多数退化趋势。

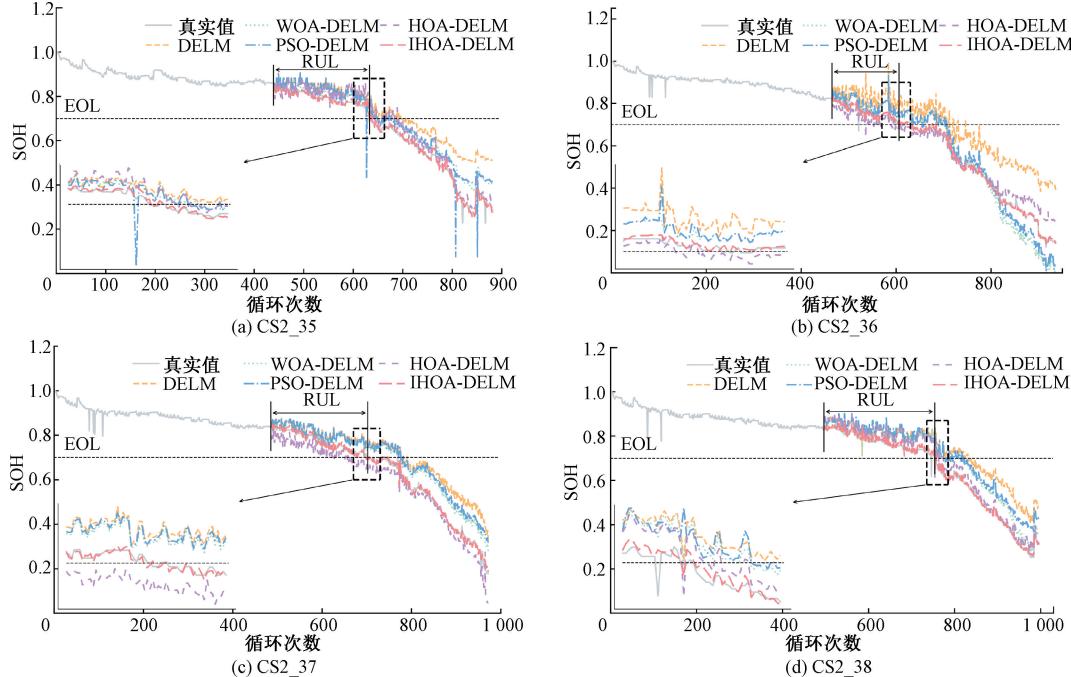


图 9 SOH 和 RUL 预测曲线

Fig. 9 SOH and RUL prediction curves

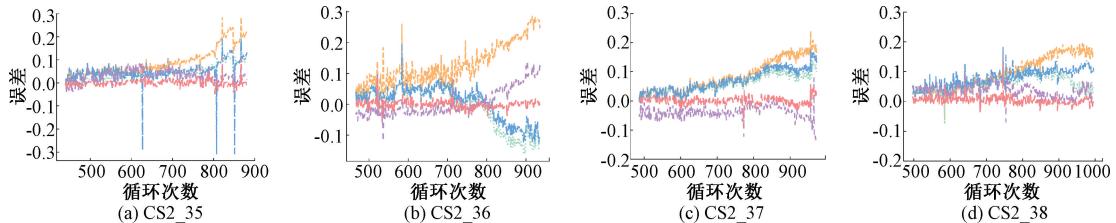


图 10 SOH 预测误差曲线

Fig. 10 SOH prediction error curve

图 11 为不同模型下 4 种电池数据容量预测的 RMSE、MAE 和 MAPE 值以及 RUL 预测结果。从图中可以看出, IHOA-DELM 模型的 RMSE 值保持在 1.21%~1.31% 之间, MAE 值保持在 0.89%~0.95% 之间, MAPE 保持在 1.59%~1.93% 之间。而且本文模型的锂电池实际 RUL 与预测 RUL 的最大绝对误差 (absolute error, AE) 值为 3 个周期, 最小 AE 值更是达到了 1 个周期。这些结果表明利用 IHOA 优化的 DELM 模型具有良好的预测能力。

3.3 与现有预测模型的比较

本文提出的 IHOA-DELM 模型与现有先进模型在 CS2 系列四种电池上的比较结果如表 1 所示。在 RMSE 值比较时, 与文献 [25] 相比, IHOA-DELM 模型只在 CS2_37 号电池的 RMSE 值略高于文献 [25]; 与文献 [26~29] 相比, IHOA-DELM 模型在四种电池的 RMSE 值均为最低; 与文献 [30] 相比, IHOA-DELM 模型只在 CS2_38 号电池的 RMSE 值高于文献 [30]。在 MAE 值比较时,

IHOA-DELM 模型除了在 CS2_38 号电池的 MAE 值略高于文献 [30], 在其它情况下, IHOA-DELM 模型的 MAE 值都是最低的。在 RUL 预测绝对误差 (AE) 值比较时, IHOA-DELM 模型在 CS2_35 和 CS2_36 号电池的 RUL 预测 AE 值是最低的, 在其它两种电池的 RUL 预测 AE 值与文献 [26~29] 相比, 排名 (从小到大排序) 在中等, 但是 AE 值都只有 3 个周期。上述对比结果进一步说明了本文模型对于 SOH 和 RUL 的联合估计具有良好的预测效果。

3.4 模型泛化性分析

为了解 IHOA-DELM 模型在不同电池数据的泛化能力, 使用 NASA 数据集中的 B0005、B0006 和 B0007 三种电池数据进行验证实验。由于 3 种电池的种类不同, B0006 电池的 EOL 设置为 0.7, 其余 2 种电池设置的 EOL 设置为 0.8。使用 3 种电池的前 40% 数据作为训练集, 后 60% 的数据作为测试集。实验得到 3 种电池的 SOH 和

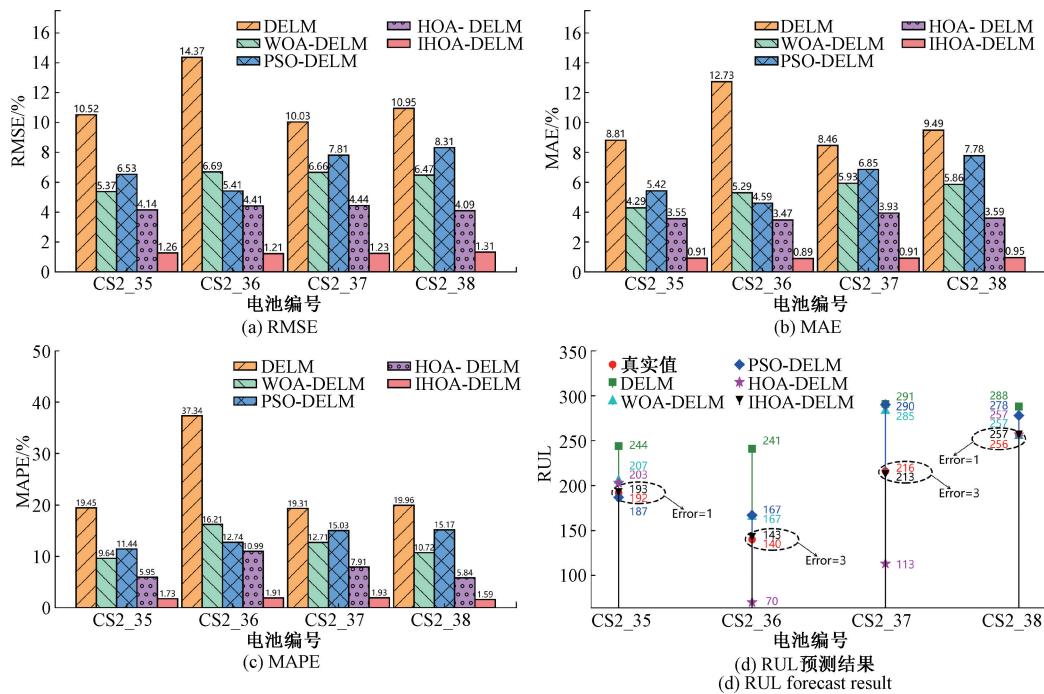


图 11 评价指标值和 RUL 预测结果

Fig. 11 Evaluation index values and RUL prediction results

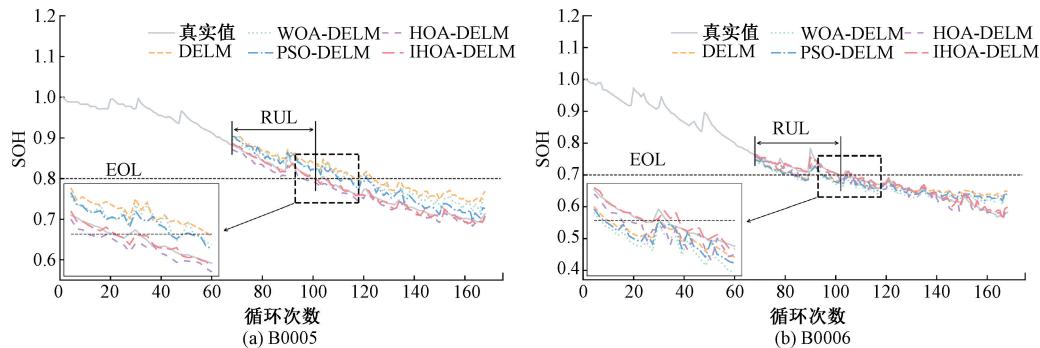
表 1 CS2 系列电池不同方法结果的比较

Table 1 Comparison of results of different methods for CS2 series batteries

模型	RMSE/%				MAE/%				AE			
	CS2_35	CS2_36	CS2_37	CS2_38	CS2_35	CS2_36	CS2_37	CS2_38	CS2_35	CS2_36	CS2_37	CS2_38
IHOA-DELM	1.26	1.21	1.23	1.31	0.91	0.89	0.91	0.95	1	3	3	1
文献[25]	1.84	2.29	1.17	1.62	1.18	1.42	1.04	1.07	—	—	—	—
文献[26]	2.58	2.02	1.92	1.91	1.35	1.57	1.36	1.36	4	2	12	2
文献[27]	1.81	2.02	1.70	—	1.81	1.37	1.15	—	6	6	2	—
文献[28]	2.46	3.00	2.16	2.23	1.62	2.19	1.51	1.59	8	1	9	19
文献[29]	1.92	2.54	1.98	1.81	1.41	2.01	1.35	1.39	8	5	0	7
文献[30]	1.31	2.12	1.47	1.12	0.95	1.64	1.12	0.93	—	—	—	—

RUL 预测曲线如图 12 所示。从图中可以看到, IHOA-DELM 模型对于 B0005、B0006 和 B0007 三种电池依然具有较好的预测能力。而且 RMSE 值在 0.66%~0.71% 之间, MAPE 值在 0.48%~0.62% 之间, MAPE 值在

0.61%~0.94% 之间, RUL 预测的最大 AE 值为 2 个周期, 最小 AE 值为 0 个周期。结果显然更好一些, 表明本文模型能够适应不同类型电池, 具有良好的泛化能力。



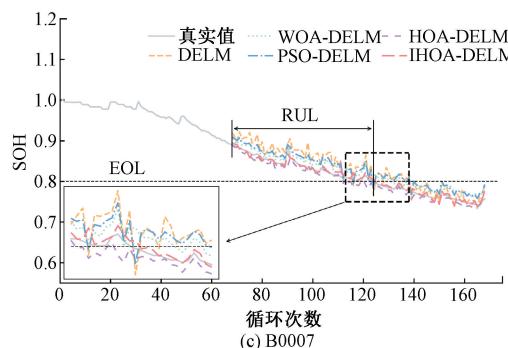


图 12 SOH 和 RUL 预测曲线

Fig. 12 SOH prediction curve

4 结 论

为了实现锂离子电池 SOH 和 RUL 联合准确预测,本文提出了一种基于 IHOA-DELM 的 SOH 和 RUL 联合预测模型。针对从充放电过程中提取的健康指标,利用 Pearson 相关分析方法提取了与电池退化相关性较高的 5 个健康指标,使用 Hampel 滤波去除指标数据中的异常值,并对数据进行归一化。其次,在利用 DELM 进行预测时,为更快更准确地找到最佳的 DELM 超参数,对传统 HOA 进行一些改进,增强其优化能力。CS2 系列 4 种电池数据集的仿真结果表明,IHOA-DELM 模型的预测精度高于其他模型。而且该模型在与其他现有预测模型的结果相比,仍然具有优越的性能。最后模型对 NASA 数据集的 3 种电池验证泛化能力时依然具有很高预测准确度。这些结果均验证了 IHOA-DELM 模型的优越性能。未来的研究工作中,将提取一些其他的健康指标与本文所提取的健康指标进行组合筛选,并尝试用其他的改进方法对 HOA 进行改进并优化 DELM 的更多超参数(隐层神经元的层数、个数等等),以实现对锂离子电池 SOH 和 RUL 的更精确的预测。

参考文献

- [1] ZHANG X H, LI ZH, LUO L AI, et al. A review on thermal management of lithium-ion batteries for electric vehicles[J]. Energy, 2022, 238: 121652.
- [2] WANG Y J, ZHANG X CH, CHEN Z H. Low temperature preheating techniques for lithium-ion batteries: Recent advances and future challenges[J]. Applied Energy, 2022, 313: 118832.
- [3] SEOK J, LEE W, LEE H, et al. Aging mechanisms of lithium-ion batteries[J]. Journal of Electrochemical Science and Technology, 2024, 15(1): 51-66.
- [4] AKASH B, ZINEB S, ERIC G, et al. Review on state of health estimation methodologies for lithium-ion batteries in the context of circular economy[J]. CIRP Journal of Manufacturing Science and Technology, 2021, 32: 517-528.
- [5] FENG H L, YAN H M. State of health estimation of large-cycle lithium-ion batteries based on error compensation of autoregressive model[J]. Journal of Energy Storage, 2022, 52: 104869.
- [6] SARMAH S B, KALITA P, GARG A, et al. A review of state of health estimation of energy storage systems: Challenges and possible solutions for futuristic applications of li-ion battery packs in electric vehicles [J]. Journal of Electrochemical Energy Conversion and Storage, 2019, 16(4): 040801.
- [7] YAO X Y, CHEN G L, HU L Y, et al. A multi-model feature fusion model for lithium-ion battery state of health prediction [J]. Journal of Energy Storage, 2022, 56: 106051.
- [8] PETKOVSKI E, MARRI I, CRISTALDI L, et al. State of health estimation procedure for lithium-ion batteries using partial discharge data and support vector regression[J]. Energies, 2023, 17(1): 206.
- [9] HE Y, BAI W Y, WANG L L, 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: 110678.
- [10] ZHANG CH Y, WANG SH L, YU CH M, et al. Improved particle swarm optimization-extreme learning machine modeling strategies for the accurate lithium-ion battery state of health estimation and high-adaptability remaining useful life prediction [J]. Journal of the Electrochemical Society, 2022, 169(8): 080520.
- [11] REN L, ZHAO L, HONG SH, et al. Remaining useful life prediction for lithium-ion battery: A deep learning approach [J]. IEEE Access, 2018, 6: 50587-50598.
- [12] MA Y Y, WU L F, GUAN Y, et al. The capacity estimation and cycle life prediction of lithium-ion batteries using a new broad extreme learning machine approach [J]. Journal of Power Sources, 2020,

- 476: 228581.
- [13] BELLOMO M, GIAZITZIS S, BADHA S, et al. Deep learning regression with sequences of different length: An application for state of health trajectory prediction and remaining useful life estimation in lithium-ion batteries[J]. *Batteries*, 2024, 10(8): 292.
- [14] 李红磊, 刘勋川, 高强, 等. 基于TCT-PSA模型的锂离子电池健康状态评估[J]. *电子测量技术*, 2024, 47(12): 122-131.
- LI H L, LIU X CH, GAO Q, et al. Lithium-ion battery state of health estimation based on TCT-PSA modeling[J]. *Electronic Measurement Technology*, 2024, 47(12): 122-131.
- [15] WANG L J, PING D ZH, WANG CH G, et al. Fault diagnosis of rotating machinery bearings based on improved DCNN and WOA-DELM[J]. *Processes*, 2023, 11(7): 1928.
- [16] WU T ZH, HUANG Y H, XU Y H, et al. SOH prediction for lithium-ion battery based on improved support vector regression[J]. *International Journal of Green Energy*, 2023, 20(3): 227-236.
- [17] ZHANG B D, LIU W, CAI Y X, et al. State of health prediction of lithium-ion batteries using particle swarm optimization with Levy flight and generalized opposition-based learning [J]. *Journal of Energy Storage*, 2024, 84: 110816.
- [18] 陈新岗, 赵龙, 马志鹏, 等. 基于ISSA-CNN-BiGRU-Attention的锂电池健康状态评估[J]. *电子测量技术*, 2024, 47(8): 22-30.
- CHEN X G, ZHAO L, MA ZH P, et al. Lithium battery health status assessment based on ISA-CNN-BiGUR-Attention [J]. *Electronic Measurement Technology*, 2024, 47(8): 22-30.
- [19] 郭喜峰, 黄裕海, 单丹, 等. 改进全局ZOA优化MVMD-SCN的锂电池SOH估算[J]. *电子测量技术*, 2024, 47(5): 22-30.
- GUO X F, HUANG Y H, SHAN D, et al. Improved global ZOA optimization of MVMD-SCN for lithium battery SOH estimation[J]. *Electronic Measurement Technology*, 2024, 47(5): 22-30.
- [20] SHABBIR M, CHAND S, IQBAL F, et al. Hybrid Approach for streamflow prediction: LASSO-hampel filter integration with support vector machines, artificial neural networks, and autoregressive distributed lag models [J]. *Water Resources Management*, 2024, 38(11): 4179-4196.
- [21] AMIRI M H, HASHJIN N M, MONTAZERI M, et al. Hippopotamus optimization algorithm: A novel nature-inspired optimization algorithm[J]. *Scientific Reports*, 2024, 14(1): 5032.
- [22] JIN S S, KIM G, KWAG S, et al. Feasibility study of progressive Latin hypercube sampling and quasi-Monte Carlo simulation for probabilistic risk assessment[J]. *Geomatics, Natural Hazards and Risk*, 2024, 15(1): 2425185.
- [23] RAO R. Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems [J]. *International Journal of Industrial Engineering Computations*, 2016, 7(1): 19-34.
- [24] WU L, CHEN ER Q, GUO Q, et al. Smooth exploration system: A novel ease-of-use and specialized module for improving exploration of whale optimization algorithm [J]. *Knowledge-Based Systems*, 2023, 272: 110580.
- [25] PAN R, LIU T SH, HUANG W, et al. State of health estimation for lithium-ion batteries based on two-stage features extraction and gradient boosting decision tree[J]. *Energy*, 2023, 285: 129460.
- [26] TANG X L, WAN H, WANG W W, et al. Lithium-ion battery remaining useful life prediction based on hybrid model[J]. *Sustainability*, 2023, 15(7): 6261.
- [27] YIN C B, SHEN X Y, WANG CH B, et al. Remaining useful life prediction of lithium-ion batteries based on DBOCNN-DSformer[J]. *Electrochimica Acta*, 2024, 508: 145123.
- [28] ZHOU K L, ZHANG ZH Y. Remaining useful life prediction of lithium-ion batteries based on data denoising and improved transformer[J]. *Journal of Energy Storage*, 2024, 100: 113749.
- [29] WANG T Y, MA ZH J, ZOU S L. Remaining useful life prediction of lithium-ion batteries: A temporal and differential guided dual attention neural network[J]. *IEEE Transactions on Energy Conversion*, 2023, 39: 757-771.
- [30] YUAN Z F, TIAN T, HAO F CH, et al. A hybrid neural network based on variational mode decomposition denoising for predicting state-of-health of lithium-ion batteries[J]. *Journal of Power Sources*, 2024, 609: 234697.

作者简介

曹旭,硕士研究生,主要研究方向为锂离子电池的健康状态和剩余使用寿命的预测。

E-mail:279914074@qq.com

惠周利,副教授,博士,主要研究方向为机器学习及其应用。

E-mail:13994208298@139.com

杨明(通信作者),副教授,硕士,主要研究方向为数据分析与图像信息处理。

E-mail:hgsnj@163.com