

DOI: 10.13382/j.jemi.B2407835

基于最优重构健康因子和 RIME-SVR 的 锂电池健康状态估计研究*

杨东晓 王贺 党宏宇 袁宇轩 和杰公

(北京林业大学工学院 北京 100083)

摘要:为提高锂电池健康状态(SOH)估计精度,提出一种基于最优重构健康因子和霜冰算法优化支持向量回归(RIME-SVR)相融合的估计方法。首先从锂电池充放电过程提取3个可测量健康因子,利用Pearson法分析验证其与SOH相关性;其次利用完备集合经验模态分解算法(CEEMDAN)对健康因子分解重构,通过实验验证法确定最优重构方式,有效降低数据噪声和容量回升现象对SOH估计干扰;最后搭建基于RIME算法优化的SVR估计模型。实验采用NASA电池退化数据,结果表明,相比于粒子群(PSO)和人工蜂群(ABC)优化算法,RIME优化SVR参数时表现出更快收敛速度和更强全局搜索能力,显著提升模型性能。此外,基于最优重构健康因子和RIME-SVR的锂电池SOH估计模型3项指标均优于对比实验中其他模型,具有更高的估计精度和拟合度。使用最优重构健康因子 $Dw_1+Ti_1+Tdv_1$ 作为输入,模型平均绝对误差(MAE)、均方根误差(RMSE)分别低于0.37和0.55, R^2 高于0.92,表明所提方法具备良好的普适性和鲁棒性。

关键词: 锂电池健康状况;最优重构健康因子;霜冰优化算法;支持向量回归;CEEMDAN

中图分类号: TN86;TM912 **文献标识码:** A **国家标准学科分类代码:** 120.30

Estimation of lithium battery health state based on optimal reconstructed health factor and RIME-SVR

Yang Dongxiao Wang He Dang Hongyu Yuan Yuxuan He Jiegong

(School of Technology, Beijing Forestry University, Beijing 100083, China)

Abstract: In order to improve the estimation accuracy of lithium battery state of health (SOH), a novel estimation method combining the optimal reconstruction of Health Indicators and RIME-optimized support vector regression (RIME-SVR) is proposed. First, three measurable Health Indicators are extracted from the charging and discharging process of lithium batteries, and their correlation with SOH is verified using the Pearson method. Subsequently, the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) algorithm is employed to decompose and reconstruct the health indicators. The optimal reconstruction method is determined through experimental validation, effectively reducing the interference of data noise and capacity recovery on SOH estimation. Finally, an SVR estimation model optimized by the RIME algorithm is established. The experiments are conducted using NASA battery degradation data. The results show that compared with particle swarm optimization (PSO) and artificial bee colony (ABC) algorithms, RIME exhibits faster convergence speed and stronger global search capability when optimizing SVR parameters, significantly enhancing model performance. Moreover, the lithium battery SOH estimation model based on the optimal reconstruction of health indicators and RIME-SVR outperforms other models in the comparative experiments in terms of three indicators, achieving higher estimation accuracy and fitting degree. When the optimally reconstructed health indicator $Dw_1+Ti_1+Tdv_1$ is used as input, the model's average mean absolute error (MAE) is below 0.37, root mean squared error (RMSE) is below 0.55, and the coefficient of determination is higher than 0.92, indicating good universality and robustness.

Keywords: lithium battery health; optimal reconstruction of health factors; rime-ice algorithm; support vector regression; CEEMDAN

0 引言

锂电池因其高能量密度、高充放电效率以及绿色环保等特性,在民用电器、电力系统和航空航天等领域得到广泛应用。然而,在充放电循环过程中,锂电池内部会发生一系列电化学反应,导致材料降解和性能退化,影响设备正常运行。因此,准确估计锂电池健康状况 (state of health, SOH) 对保障电池系统安全稳定运行具有重要意义。

当前,国内外对锂电池 SOH 研究主要分为模型驱动和数据驱动两大类方法^[1]。模型驱动法通过建立不同物理模型反映电池衰退过程中的电化学特性^[2],根据建模原理可分为电化学模型、等效电路模型和经验退化模型 3 种^[3]。该方法需充分考虑电池机理变化,易受噪声和环境干扰,建立精确退化模型困难^[4]。数据驱动法无需考虑电池内部复杂机理变化,仅通过对锂电池历史数据挖掘来估计锂电池健康状况^[5]。常见数据驱动模型有人工神经网络模型 (artificial neural networks, ANN)^[6-7]、高斯过程回归模型 (gaussian process regression, GPR)^[8]、支持向量机模型 (support vector machine, SVM)^[9] 以及差分整合移动平均自回归模型 (autoregressive integrated moving average, ARIMA)^[10] 等,但电池退化过程存在容量回升现象,并且各种因素的影响导致电池数据携带大量噪声,锂电池 SOH 预测仍充满挑战^[11]。

为解决电池退化过程容量回升现象以及数据噪声干扰问题,模态分解算法不失为一种有效解决方案^[12]。Cheng 等^[13]提出一种结合经验模态分解算法 (empirical mode decomposition, EMD) 的神经网络模型,该方法对容量回升现象和噪声问题起到一定抑制作用。但 EMD 算法本身存在端点效应和模态混叠问题,给研究带来新的困扰。牛群峰等^[11]提出一种基于完备集合经验模态分解方法 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN) 的融合模型,克服了 EMD 算法缺陷,降低了预测误差,但该研究着重关注锂电池容量,忽略了对健康因子 (health indicator, HI) 的研究。杨彦茹等^[14]提出基于 CEEMDAN 和支持向量回归 (SVR) 的锂电池寿命预测模型,选取单一 HI 对锂电池寿命预测,但未考虑不同 HI 间相互关系,预测精度仍有提升空间。电池健康状态估计精度不仅取决于模型性能,还取决于对 HI 的研究和处理。因此,要进一步提升锂电池健康状况估计精度,需要从 HI 的选取重构和模型性能优化两方面入手。

针对上述问题,提出一种最优重构健康因子 (HIS) 和 RIME-SVR 模型算法相结合的锂电池 SOH 估计模型。首先,从锂电池充放电数据中提取 3 个 HI,利用

CEEMDAN 算法对 HI 数据进行处理;其次设计对比实验探究最优重构 HIS;之后建立 SVR 估计模型,并采用霜冰优化算法 (rime optimization algorithm, RIME) 对模型关键参数优化;最后确定锂电池 SOH 最优估计模型,利用 NASA 提供的电池退化数据进行实验验证。研究结果表明,基于最优重构 HIS 和 RIME-SVR 估计模型能够很好地跟踪锂电池 SOH 变化趋势,拥有更好的估计效果。

1 涉及算法

1.1 CEEMDAN

CEEMDAN 由 EEMD 改进而来,可有效解决模态混叠问题并降低集成次数,减小重构误差^[14]。

1) 将 n 组自适应高斯白噪声 $\delta_0 \varepsilon_n(t)$ 添加至待分解序列中获得 n 个新数据序列 $x^n(t)$:

$$x^n(t) = x(t) + \delta_0 \varepsilon_n(t), n = \{1, 2, \dots\} \quad (1)$$

2) 对 $x^n(t)$ 进行 EMD 分解并取均值得到 CEEMDAN 的第 1 个 IMF 分量,原始信号减去 IMF₁ 获得残余分量 $r_1(t)$:

$$IMF_1 = \frac{1}{n} \sum_1^n c_1^n(t), n = \{1, 2, \dots\} \quad (2)$$

$$r_1(t) = x(t) - IMF_1 \quad (3)$$

式中: $c_1^n(t)$ 为分解信号。

3) 将残余分量 $r_i(t)$ 视为新待分解序列,重复以上步骤直到满足 EMD 的停止条件,获得最终分解结果,原始信号 $x(t)$ 可表示为 k 个 IMF 分量和一个残余分量 $R(t)$,如式(4)所示。

$$x(t) = \sum_1^k IMF_k + R(t) \quad (4)$$

1.2 霜冰优化算法

Hang 等^[15]提出一种基于自然现象的元启发式算法——霜冰优化算法,该算法通过模拟软霜冰和硬霜冰在不同风速中的生长行为,实现了优化问题的搜索与开发过程,平衡了全局探索和局部开发能力。RIME 算法主要包括软霜冰搜索策略、硬霜冰穿刺机制和积极贪婪选择机制,这些机制相互配合,使算法在复杂优化问题中表现出色。

首先初始化霜冰种群,整个种群由多个霜冰簇组成,每个霜冰簇代表一个潜在解,每个簇包含多个霜冰粒子,粒子数量等于问题维度。种群初始化过程可用式(5)所示矩阵表示。

$$\mathbf{R} = \begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_i \end{bmatrix}, S_i = [x_{i1}, x_{i2}, \dots, x_{ij}] \quad (5)$$

式中: S_i 表示第 i 个霜冰簇; x_{ij} 表示第 i 个霜冰簇的第 j 个霜冰粒子。种群大小为 n , 维度为 d 。每个霜冰簇的适应度函数 $F(S_i)$ 表示其生长状态和在搜索空间中的优势。

软霜冰搜索策略通过模拟微风环境下霜冰粒子随机生长行为, 实现算法全局探索。在微风环境中, 霜冰生长方向不定, 生长速度较慢但覆盖范围广, 这种特性使算法在初期能广泛覆盖搜索空间。软霜冰搜索粒子位置更新公式如式(6)所示。

$$\begin{cases} R_{ij}^{new} = R_{ij}^{best} + r_1 \beta \cos \theta (\varphi (U_{b_{ij}} - L_{b_{ij}}) + L_{b_{ij}}) \\ r_2 < E \\ \theta = \pi \frac{h}{10H} \\ \beta = 1 - \left[\frac{\omega h}{H} \right] / \omega \\ E = \sqrt{(h/H)} \end{cases} \quad (6)$$

式中: R_{ij}^{best} 为当前种群最优簇的第 j 个粒子; R_{ij}^{new} 为更新后粒子位置; r_1 为 $(-1, 1)$ 内随机数, 用于控制粒子运动方向; θ 为步长函数; β 为模拟环境因素收敛函数, 其值随迭代次数增加逐渐减小以保证算法收敛; ω 用于控制函数段数; φ 是 $(0, 1)$ 内随机数, 表示粒子粘附度, 用于控制粒子间距; $U_{b_{ij}}$ 和 $L_{b_{ij}}$ 分别为粒子运动上下边界; r_2 为 $(0, 1)$ 内随机数, E 为附着系数, 它与 r_2 控制粒子是否凝结, 即粒子位置是否更新; h 为当前迭代次数; H 为最大迭代次数。

硬霜冰穿刺机制模拟强风环境霜冰生长行为, 用于算法局部开发。在强风环境中, 霜冰生长方向固定且快速, 导致霜冰簇之间易发生“穿刺”现象, 即不同簇间信息交换。硬霜冰穿刺机制通过式(7)进行粒子更新。

$$R_{ij}^{new} = R_{ij}^{best}, r_3 < F_{norm_r}(S_i) \quad (7)$$

式中: $F_{norm_r}(S_i)$ 表示当前簇适应度归一化值; r_3 为 $(-1, 1)$ 随机数, 用于控制簇间交叉更新。此机制引入有助于算法跳出局部最优, 提高求解精度。

为进一步提高搜索效率并增加种群多样性, RIME 引入积极贪婪选择机制。传统选择机制仅在每次迭代后记录最优解, 而 RIME 积极贪婪选择机制则允许劣质解在一定条件下被替换为次优解, 从而增加种群多样性并促进全局探索。其核心是每次迭代后将当前解与先前解比较, 并根据结果选择是否替换, 公式如式(8)所示。

$$F(R_i^{new}) < F(R_i) \Rightarrow R_i = R_i^{new} \quad (8)$$

通过此机制, RIME 不仅保证解的质量, 还通过不同簇替换操作积极推动种群朝更优方向演化, 避免算法陷入局部最优。

1.3 支持向量回归

支持向量回归常用来解决小样本、非线性问题, 在机

器学习中被广泛应用^[16]。假设给定 n 个训练样本 $D = \{(x_i, y_i)\}_{i=1}^n$, 其中 $x_i \in X = \mathbf{R}^n, y_i \in Y = \mathbf{R}, i = 1, \dots, l$ 。

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^l l_{\varepsilon}(f(x_i) - y_i) \quad (9)$$

式中: c 为惩罚因子; l_{ε} 为敏感损失函数; $\varepsilon (\varepsilon > 0)$ 为最大允许误差。引入松弛变量 Θ_i 和 Θ_i^* 则可将原优化问题转化为二次凸优化问题。

$$\min_{\omega, b, \Theta, \Theta^*} \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^l (\Theta_i + \Theta_i^*) \quad (10)$$

$$\begin{cases} f(x_i) - y_i \leq \varepsilon + \Theta_i \\ y_i - f(x_i) \leq \varepsilon + \Theta_i^* \\ \Theta_i, \Theta_i^* \geq 0, i = 1, \dots, l \end{cases} \quad (11)$$

可以利用核函数来解决线性不可分的问题, 其原理为通过非线性变换将数据从原始空间映射到一个更高维的特征空间, 从而使得原本线性不可分的样本在新的特征空间中线性可分。

利用拉格朗日乘子 $\alpha_i \geq 0$, 核函数 $K(x_i, x_j)$ 和惩罚因子 c , 可将原问题转化为对偶问题, 求解后最终得到 SVR 的表达式:

$$f(x) = \sum_i^n (-\alpha_i + \alpha_i^*) K(x, x_i) + b \quad (12)$$

其中核函数通常选取高斯核函数:

$$K(x_i, x_j) = \exp\left(-\frac{1}{2\sigma^2} \|x_i - x_j\|^2\right) \quad (13)$$

式中: σ 为核参数, 为使模型预测更加精确, 必须选择合适的参数。

1.4 RIME 优化 SVR 过程

RIME-SVR 利用 RIME 算法强大的全局搜索能力及其高效的参数更新机制来搜索 SVR 模型最优参数。RIME-SVR 算法的流程如图 1 所示。

1) 对 RIME 及 SVR 模型的各项参数初始化。设定 RIME 霜冰种群的大小, SVR 的惩罚参数 c 和核参数 σ 上下界 $U_{b_{ij}}$ 和 $L_{b_{ij}}$, 以及迭代次数 H 。

2) 输入训练数据集, 构建 SVR 的预测模型, 设定均方误差 (MSE) 为适应度函数。

3) 根据当前迭代次数 h 与总迭代次数 H 比值计算粒子附着系数 E , 当随机数 $r_2 < E$ 时, 根据式(6)更新霜冰粒子位置。

4) 根据归一化适应度值 $F_{norm_r}(S_i)$ (MSE) 控制粒子位置更新。若随机数 $r_3 < F_{norm_r}(S_i)$, 则更新粒子位置。

5) 比较每个新位置适应度值与当前位置适应度值, 更新最优粒子位置和最优适应度值。如果新解优于先前解, 则替换最优解。

6) 如果满足循环条件, 且当 $h < H$ 时, 输出最佳参数组合 c, σ , 将其代入 SVR 训练, 算法结束。若未满足条件, 则更新迭代次数 h , 进入下一轮迭代, 直至满足条件。

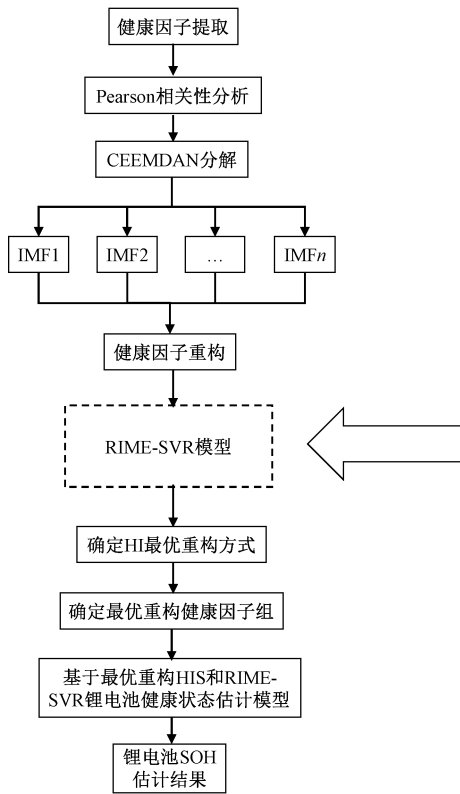
2 SOH 估计模型建模流程

当前国际上对锂电池 SOH 研究多以容量为主,定义为:

$$SOH = \frac{C_c}{C_0} \times 100\% \quad (14)$$

式中: C_c 为当前测得最大放电容量; C_0 为额定容量。可用二者百分比定义锂电池 SOH^[17]。

本文利用 CEEMDAN 对锂电池 HI 分解重构,通过设计两种不同对比实验,确定 HI 最优重构方式以及最优重构 HI 组合,结合 RIME 优化 SVR 建立锂电池 SOH 预测模型,算法流程如图 1 所示。



1) 提取 3 个表征锂电池退化 HI 数据,利用 Pearson 法分析验证;

2) 利用 CEEMDAN 算法将 HI 有效分解并重构,其中 80%作训练集,20%作测试集,进行归一化处理;

3) 通过 RIME 算法对 SVR 待定参数优化建立 RIME-SVR 模型;

4) 选择相关系数最高 HI 作为 RIEM-SVR 模型输入进行重构实验,确定数据最优重构方式;

5) 利用步骤 4) 中最优重构方式构建不同 HI 组作为模型输入进行实验,得到以最优重构 HIS 作为输入的锂电池 SOH 估计模型;

6) 使用基于最优重构 HIS 的 RIME-SVR 模型对锂电池 SOH 预测。

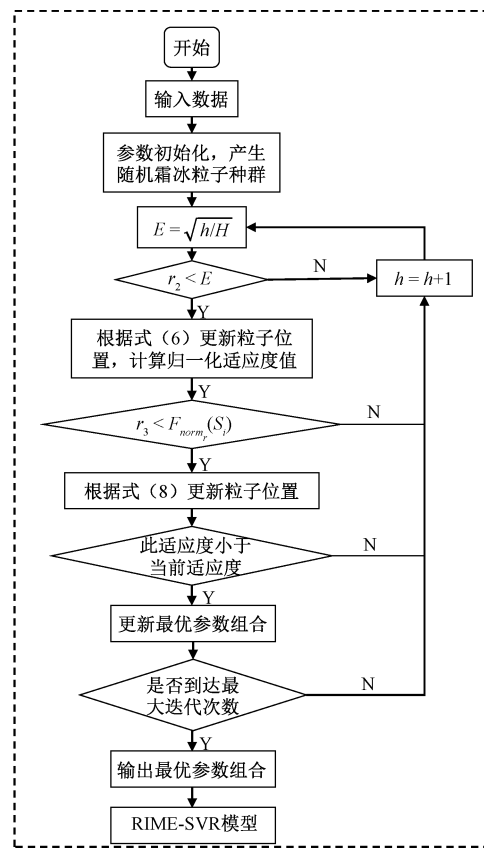


图 1 估计模型建模流程

Fig. 1 Estimation model modeling flow chart

3 实验结果与分析

3.1 实验数据分析

研究实验数据来自 NASA PCoE 电池测试数据集^[14],采用其中 B05、B06、B07、B18 四组 18650 型钴酸锂电池充放电循环数据,数据集 SOH 衰减曲线如图 2

所示。

以 B05 电池数据集为例对电池充放电过程中电流、电压随循环次数变化分析,分别提取出对应 3 种 HI 数据,即充电阶段恒流充电时间 T_i 、等电压上升时间间隔 T_{dv} 以及放电阶段等电压下降时间间隔 D_{tv} ,其中 D_{tv} 电压区取 3.5~4.1 V。充电阶段 T_i 和 T_{dv} 可反映电池在充电过程中内阻变化和极化现象,而放电阶段随着电池老化,内部材料退化和内阻增加会导致电压下降速率加




图 2 锂电池 SOH 变化曲线

Fig. 2 SOH change curve of lithium battery

快, D_{tw} 缩短^[18]。通过同时考虑充、放电阶段特征,可更全面评估电池健康状态。

计算各特征参数与电池 SOH 皮尔逊相关系数^[19],结果如表 1 所示。分析表 1 数据可知,4 组电池数据 D_{tw} 与对应电池 SOH 相关性最高,均在 0.97 以上,将其定为最佳单 HI; T_i 、 T_{dv} 相关系数均在 0.75 以上,可以认为其与对应锂电池 SOH 具有一定相关关系,作为实验待定义 HI。

表 1 Pearson 相关系数

Table 1 Pearson correlation coefficient

电池	D_{tw}	T_i	T_{dv}
B05	0.996 3	0.860 8	0.832 6
B06	0.971 6	0.908 7	0.903 7
B07	0.998 7	0.819 4	0.829 7
B18	0.996 7	0.768 3	0.776 3

3.2 模型评价指标

选择平均绝对误差 (mean absolute error, MAE), 均方根误差 (root mean square error, RMSE) 和决定系数 R^2 作为评估标准对模型预测方法进行评价^[20-21]。

1) 平均绝对误差为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i| \quad (15)$$

2) 均方根误差为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2} \quad (16)$$

3) 决定系数为:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - Y'_i)^2}{\sum_{i=1}^n (Y_i - M)^2} \quad (17)$$

式中: Y_i 为实际值; Y'_i 为预测值; n 为样本数。MAE、RMSE 越小, R^2 越接近 1, 模型估计效果越好。

3.3 实验结果与分析

为验证所提算法和模型有效性并探究最优 SOH 估

计模型,设计 3 组实验:RIME 与常见优化算法 PSO、ABC 性能比较实验;单健康因子最优分解重构方式探究实验;基于最优重构 HIS 和 RIME-SVR 锂电池 SOH 估计模型优化实验。在实验过程中所有模型实验均采用相同参数与样本,选择 4 组电池数据前 80% 样本作为训练样本集,剩余 20% 作测试样本集。

1) RIME 优化 SVR 性能分析

为探究 RIME 算法在 SOH 估计中的优越性,设计了与 PSO 算法、ABC 算法的对比实验。

以 B05 电池状态估计为实验对象,实验中,3 种算法均用于优化 SVR 模型关键参数。实验设置相同初始条件,3 种优化算法种群数量均设为 20,迭代次数设为 30 次,学习因子都设为 2。实验结果表明,RIME 在适应度收敛速度和全局最优解搜索能力上显著优于 PSO 和 ABC。图 3 所示为 3 种算法优化过程适应度变化曲线,从图 3 可看出 RIME 能够更快收敛到更优解,且在迭代过程中表现出较强稳定性。

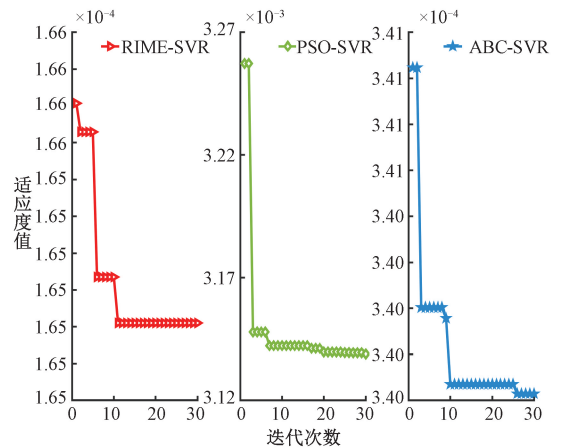


图 3 RIME、PSO 和 ABC 适应度收敛对比

Fig. 3 Comparison of fitness convergence among RIME, PSO, and ABC

表 2 为 3 种算法在优化 SVR 参数后的模型回归拟合能力,结果显示,RIME 优化的 SVR 回归模型的回归性能最优,其平均适应度值最低仅为 0.000 17,标准差最小为 $9.965 4 \times 10^{-8}$ 。

表 2 3 种算法优化 SVR 参数性能对比

Table 2 Performance comparison of three algorithms in optimizing SVR parameters

算法	平均适应度	标准差
RIME	0.000 17	$9.965 4 \times 10^{-8}$
PSO	0.003 15	$2.940 5 \times 10^{-5}$
ABC	0.000 34	$3.606 3 \times 10^{-7}$

综上所述,RIME 在优化 SVR 参数时表现出更快收敛速

度和更强全局搜索能力,为锂电池 SOH 估计模型提供了更优的参数配置。与 PSO 和 ABC 相比,RIME 在稳定性和可靠性方面具有显著优势,适用于该问题的优化。

2) 健康因子最优重构结果与分析

将 B05、B06、B07 和 B18 四组电池 D_{tw} 利用 CEEMDAN 算法逐一进行分解重构。以 B05 电池为例,分解结果如图 4 所示。可以观察到 D_{tw} 对应 IMF 分量由上至下从高频逐渐过渡到低频。不同 IMF 分量包含信号不同成分特征,信号主要特征通常由低频部分决定,高频信号中包含众多干扰噪声^[22]。为此将分解后信号按 $n-1, n-2, n-3$ (n 为 IMF 分量的总数) 形式依次滤除不同数量高频干扰信号后保留残差以及部分低频 IMF 分量来进行数据重构^[23], 重构后数据分别记作 D_{tw_1} 、 D_{tw_2} 和 D_{tw_3} , 利用重构 HI 进行对比实验探究最优重构方式。




图 4 CEEMDAN 分解曲线

Fig. 4 CEEMDAN decomposition curve

将 B05、B06、B07 和 B18 电池对应的 D_{tw} 、 D_{tw_1} 、 D_{tw_2} 和 D_{tw_3} 分别作为 RIME-SVR 模型输入来估计电池 SOH, 结果评价指标如表 3 所示, 可知除 B06 外 B05、B07 和 B18 电池 D_{tw_1} 的 MAE、RMSE 值均为最小值, R^2 为最大值; 其次 B05、B07 和 B18 电池 D_{tw_1} 、 D_{tw_2} 和 D_{tw_3} 总体呈现 MAE、RMSE 值依次增加, R^2 依次减小的规律。

以上结果说明滤除频率最高 IMF 分量重构后数据能够在保留原数据特征的基础上降低数据噪声和容量回升的不利影响, 但随着高频 IMF 分量滤除个数增加会导致原数据特征损失增多, 给电池 SOH 估计带来不利影响。为此将去除最高频率 IMF 分量后重构定为最优重构方式。

3) SOH 估计模型实验结果与分析

采用健康因子最优重构方式对 4 组电池 3 个 HI 分解重构得到新 HI—— D_{tw_1} 、 T_{i_1} 和 T_{dv_1} 。为保证高精度预测结果的同时进一步探究 HI 数量对模型估计精度的影响, 将 D_{tw_1} 、 $D_{tw_1}+T_{i_1}$ 、 $D_{tw_1}+T_{dv_1}$ 以及 $D_{tw_1}+T_{i_1}+T_{dv_1}$ 分别

作为 RIME-SVR 锂电池 SOH 估计模型输入来进行对比实验确定最优重构 HIS, 获得 SOH 最佳估计模型。

表 3 单输入预测结果评价指标

Table 3 Single input prediction result evaluation index				
电池	ENTRY	MAE	RMSE	R^2
B05	D_{tw}	0.340 97	0.455 38	0.897 83
	D_{tw_1}	0.304 52	0.448 43	0.900 93
	D_{tw_2}	0.313 40	0.478 52	0.887 19
	D_{tw_3}	0.341 14	0.478 90	0.887 01
	D_{tw}	2.280 50	3.019 10	-0.296 50
B06	D_{tw_1}	3.068 70	3.990 89	-1.173 30
	D_{tw_2}	2.136 40	2.796 00	-0.111 97
	D_{tw_3}	1.621 20	1.936 40	0.466 64
	D_{tw}	0.181 80	0.240 25	0.967 77
	D_{tw_1}	0.180 55	0.235 63	0.968 60
B07	D_{tw_2}	0.218 36	0.304 35	0.948 27
	D_{tw_3}	0.219 49	0.313 96	0.944 95
	D_{tw}	0.738 41	0.942 48	0.639 62
	D_{tw_1}	0.636 09	0.918 04	0.658 06
	D_{tw_2}	0.746 74	1.035 2	0.565 23
B18	D_{tw_3}	0.937 08	1.275 3	0.340 11

图 5 所示是 4 组电池分别使用 RIME-SVR、CEEMDAN-RIME-SVR (最佳单 HI 为输入) 以及基于最优重构 HIS 和 RIME-SVR 锂电池 SOH 估计模型 SOH 预测曲线与实际 SOH 变化曲线对比图, 3 种模型依次记为 M1、M2 和 M3。可知, 3 种模型均能在一定程度上对锂电池 SOH 预测估计, 相比于 M1 模型, M2 和 M3 能够较好地追踪 SOH 实际变化趋势, 但 M3 相比于 M2 具有更好地拟合效果, 其原因可能是多个 HI 携带信息之间相互补充, 避免了由于单个 HI 本身携带信息不足造成的误差, 从而使 SOH 预测模型拥有更广的普适性。

实验结果如表 4 所示, 可知 B05 电池 $D_{tw_1}+T_{i_1}+T_{dv_1}$ 作为模型输入估计结果中除 MAE 略高于其他 3 种重构健康因子外, RMSE 和 R^2 值均为最佳; 其他 3 组电池以 $D_{tw_1}+T_{i_1}+T_{dv_1}$ 作为模型输入估计 SOH 结果的评价指标中 MAE、RMSE 和 R^2 均为最优值。因此, 相比于 D_{tw_1} 和 $D_{tw_1}+1$, 以 $D_{tw_1}+T_{i_1}+T_{dv_1}$ 重构 HIS 作为模型输入来估计锂电池 SOH 效果最好, 准确度最高, 因此将其定为最优重构 HIS。

为进一步验证所提模型适用性, 选择最优重构健康因子 $D_{tw_1}+T_{i_1}+T_{dv_1}$ 作为统一特征集输入, 对每组电池数据采用相同划分方式, 即前 80% 样本作训练集, 后 20% 样本作测试集来分别训练、测试电池数据。计算所有电池平均测试精度和标准差以评估模型的稳定性和普适性。计算结果如表 5 所示, 可看出使用最优重构健康因子 $D_{tw_1}+T_{i_1}+T_{dv_1}$ 作为模型输入时, 所有电池测试精度均表

现良好, MAE 平均值为 0.365 02, RMSE 平均值为 0.543 89, R^2 平均值为 0.920 57, 标准差较小, 表明所提

模型不仅在单个电池上表现出色, 而且在多个电池上也具有良好的普适性和稳定性。

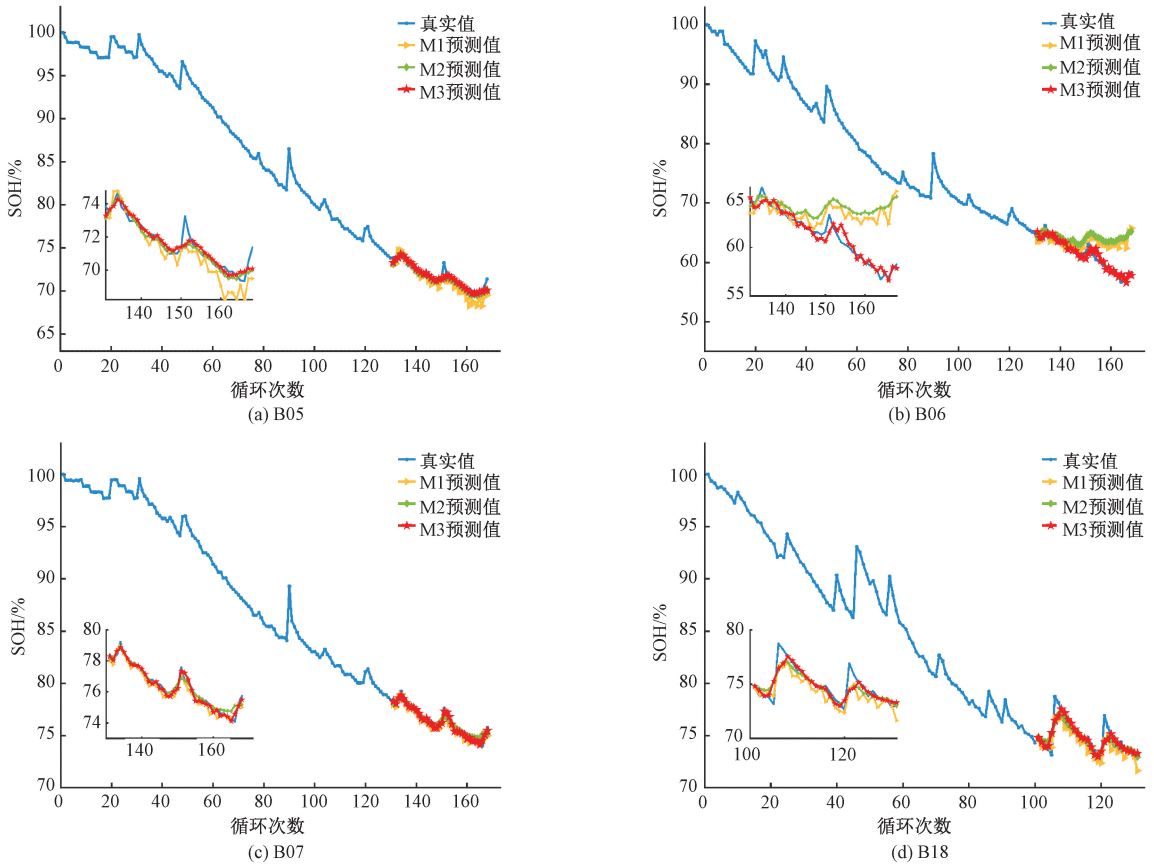


图 5 不同模型预测结果对比

Fig. 5 Comparison of prediction results of different models

表 4 重构模型预测结果评价指标

Table 4 Reconstruction model prediction results evaluation index

电池	ENTRY	MAE	RMSE	R^2
B05	Dw_1	0.304 52	0.448 43	0.900 93
	Dw_1+Ti_1	0.313 55	0.448 33	0.900 97
	Dw_1+Tdv_1	0.300 20	0.449 01	0.900 67
	$Dw_1+Ti_1+Tdv_1$	0.324 93	0.441 55	0.903 94
B06	Dw_1	3.068 70	3.990 89	-1.173 30
	Dw_1+Ti_1	0.539 92	0.740 53	0.922 00
	Dw_1+Tdv_1	0.589 01	0.801 24	0.908 68
	$Dw_1+Ti_1+Tdv_1$	0.514 66	0.678 83	0.933 06
B07	Dw_1	0.180 55	0.235 63	0.967 77
	Dw_1+Ti_1	0.199 75	0.279 10	0.956 50
	Dw_1+Tdv_1	0.167 98	0.260 21	0.962 19
	$Dw_1+Ti_1+Tdv_1$	0.166 35	0.203 90	0.976 01
B18	Dw_1	0.636 09	0.918 04	0.658 06
	Dw_1+Ti_1	0.658 19	0.941 27	0.658 19
	Dw_1+Tdv_1	0.635 69	0.919 78	0.635 69
	$Dw_1+Ti_1+Tdv_1$	0.525 12	0.905 20	0.667 56

表 5 模型平均测试精度和标准差

Table 5 Model average test accuracy and standard deviation

数据名称	MAE	RMSE	R^2
B05	0.324 93	0.441 55	0.903 94
B06	0.514 66	0.678 83	0.933 06
B07	0.166 35	0.203 90	0.976 01
B18	0.525 12	0.905 20	0.667 56
平均值	0.365 02	0.543 89	0.920 57
标准差	0.174 84	0.330 65	0.144 49

综合上述分析可知, 对 HI 进行最优重构, 能够在一定程度上抑制电池容量回升现象和数据噪声对预测结果的干扰, 提高估计精度; 同时相比于单一输入模型, 重构后携带不同特征信息的多个健康因子组成基于最优重构 HIS 和 RIME-SVR 模型能够发挥多特征优势, 进一步提升模型估计精度, 增强模型适用性。

4 结 论

本文提出一种基于最优重构健康因子和 RIME-SVR 的锂电池健康状态估计方法,通过实验验证,该方法在解决锂电池容量回升现象和数据噪声干扰问题上表现出显著优势。研究核心是利用 CEEMDAN 算法对健康因子进行分解重构,有效降低数据噪声和容量回升对 SOH 估计干扰;同时结合 RIME 优化算法的全局搜索能力和高效参数更新机制,显著提升模型预测性能;最后采用最优重构健康因子 $Dtw_1+Ti_1+Tdv_1$ 作为模型输入,充分发挥不同健康因子多特征互补优势,进一步提升模型预测精度。研究表明,所提方法 SOH 估计精度和拟合度均优于传统模型,MAE、RMSE 分别低于 0.37 和 0.55、 R^2 高于 0.92,具有良好的适用性和鲁棒性。未来工作将进一步探索多源数据融合和深度学习技术的结合,以进一步提升锂电池健康状态估计的准确性和适用性,为电池管理系统提供更可靠技术支持。

参考文献

- [1] SUN H L, SUN J R, ZHAO K, et al. Data-driven ICA-Bi-LSTM-combined lithium battery SOH estimation [J]. *Mathematical Problems in Engineering*, 2022, DOI: 10.1155/2022/9645892.
- [2] LI J F, LYU C, WANG L X, et al. Remaining capacity estimation of Li-ion batteries based on temperature sample entropy and particle filter [J]. *Journal of Power Sources*, 2014, 268: 895-903.
- [3] MA B, YANG S C, ZHANG L S, et al. Remaining useful life and state of health prediction for lithium batteries based on differential thermal voltammetry and a deep-learning model [J]. *Journal of Power Sources*, 2022, 25(12):105638.
- [4] NG M F, ZHAO J, YAN Q Y, et al. Predicting the state of charge and health of batteries using data-driven machine learning [J]. *Nature Machine Intelligence*, 2020, 2(3): 161-170.
- [5] 赵月荷, 庞宗强. 基于无迹卡尔曼滤波的动力电池健康状态估计[J]. *国外电子测量技术*, 2022, 41(10): 136-141.
ZHAO Y H, PANG Z Q. State of health estimation of power batteries based on unscented Kalman filter [J]. *Foreign Electronic Measurement Technology*, 2022, 41(10): 136-141.
- [6] PANG X Q, HUANG R, WEN J, et al. A lithium-ion battery RUL prediction method considering the capacity regeneration phenomenon [J]. *Energies*, 2019, 12(12): 1-14.
- [7] LI W H, JIAO Z P, DU L, et al. An indirect RUL prognosis for lithium-ion battery under vibration stress using Elman neural network [J]. *International Journal of Hydrogen Energy*, 2019, 44(23): 12270-12276.
- [8] XING J, ZHANG H L, ZHANG J P. Remaining useful life prediction of - Lithium batteries based on principal component analysis and improved Gaussian process regression [J]. *International Journal of Electrochemical Science*, 2023, 18(4):100048.
- [9] LI X Y, YUAN C G, WANG Z P. State of health estimation for Li-ion battery via partial incremental capacity analysis based on support vector regression [J]. *Energy*, 2020, 203:117852.
- [10] ZHOU Y P, HUANG M H. Lithium-ion batteries remaining useful life prediction based on a mixture of empirical mode decomposition and ARIMA model [J]. *Microelectronics Reliability*, 2016, 65: 265-273.
- [11] 牛群峰, 袁强, 王莉, 等. 基于 CEEMDAN-RVM-LSTM 模型的锂电池剩余寿命预测 [J]. *电源技术*, 2023, 47(10): 1313-1318.
NIU Q F, YUAN Q, WANG L, et al. Remaining life prediction of lithium-ion batteries based on CEEMDAN-RVM-LSTM model [J]. *Chinese Journal of Power Sources*, 2023, 47(10): 1313-1318.
- [12] 谢旭, 蒲娴怡, 毕贵红, 等. 基于二层分解技术的锂离子电池容量评估方法 [J]. *电源技术*, 2022, 46(6): 647-651.
XIE X, PU X Y, BI G H, et al. Capacity estimation method of lithium-ion batteries based on two-layer decomposition technique [J]. *Chinese Journal of Power Sources*, 2022, 46(6): 647-651.
- [13] CHENG G, WANG X Z, HE Y R. Remaining useful life and state of health prediction for lithium batteries based on empirical mode decomposition and a long and short memory neural network [J]. *Energy*, 2021, 232:121022.
- [14] 杨彦茹, 温杰, 史元浩, 等. 基于 CEEMDAN 和 SVR 的锂离子电池剩余使用寿命预测 [J]. *电子测量与仪器学报*, 2020, 34(12):197-205.
YANG Y R, WEN J, SHI Y H, et al. Remaining useful life prediction for lithium-ion battery based on CEEMDAN and SVR [J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(12):197-205.
- [15] HANG S, DONG Z, ASGHAR A H, et al. RIME: A physics-based optimization [J]. *Neurocomputing*, 2023, 532:183-214.
- [16] 梁杨, 周永军, 蒋淑霞, 等. 基于改进 GWO-SVR 的锂电池 SOH 估计 [J]. *电子测量技术*, 2023, 46(7):

- 13-18.
LIANG Y, ZHOU Y J, JIANG SH X, et al. Lithium battery SOH estimation based on improved GWO-SVR [J]. Electronic Measurement Technology, 2023, 46(7): 13-18.
- [17] 张朝龙, 罗来劲, 刘惠汉, 等. 基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计 [J]. 电子测量与仪器学报, 2023, 37(1): 167-176.
ZHANG CH L, LUO L J, LIU H H, et al. State of health estimation of Lithium-ion batteries based on incremental energy analysis and BiGRU-Dropout [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 167-176.
- [18] WANG X, HU B, SU X, et al. State of health estimation for lithium-ion batteries using random forest and gated recurrent unit[J]. Journal of Energy Storage, 2024, 76: 109796.
- [19] 石伟杰, 王海民. 基于锂离子电池热特性的 SOH 在线诊断模型研究 [J]. 仪器仪表学报, 2020, 41(08): 206-216.
SHI W J, WANG H M. On-line diagnosis model of SOH based on thermal characteristics of lithium-ion battery [J]. Chinese Journal of Scientific Instrument, 2020, 41(8): 206-216.
- [20] 刘琼, 张豹. 基于 GBDT 算法的锂电池剩余使用寿命预测 [J]. 电子测量与仪器学报, 2022, 36(10): 166-172.
LIU Q, ZHANG B. Remaining useful lifetime prediction for lithium battery based on GBDT algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 166-172.
- [21] 李强龙, 孙建瑞, 赵坤, 等. 基于 IALO-SVR 的锂电池健康状态预测 [J]. 电子测量与仪器学报, 2022, 36(1): 204-211.
LI Q L, SUN J R, ZHAO K, et al. Prediction for the state of health of lithium-ion batteries based on IALO-SVR [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 204-211.
- [22] LIU Y, ZUO H, LIU Z, et al. Electrostatic signal self-adaptive denoising method combined with CEEMDAN and wavelet threshold[J]. Aerospace, 2024, 11(6): 491.
- [23] ZHANG J Q, CHEN Y G, LI N, et al. A denoising method of micro-turbine acoustic pressure signal based on CEEMDAN and improved variable step-size NLMS algorithm[J]. Machines, 2022, 10(6): 444-444.

作者简介



杨东晓, 2023 年于北京林业大学获得学士学位, 为北京林业大学硕士研究生, 主要研究方向为热电转换和储能方向。

E-mail: 1733671409@qq.com

Yang Dongxiao received his B. Sc. degree from Beijing Forestry University in 2023. Now he is a M. Sc. candidate at Beijing Forestry University. His main research interests include thermoelectric conversion and energy storage.



王贺(通信作者), 2009 年于湖南大学获得学士学位, 2014 年于武汉大学获得博士学位, 现为北京林业大学副教授, 主要研究方向为数据驱动与机器学习融合建模在新型电力系统中的应用。

E-mail: wanghe@bju.edu.cn

Wang He (Corresponding author) received his B. Sc. degree from Hunan University in 2009, and Ph. D. degree from Wuhan University in 2014. Now he is an associate professor at Beijing Forestry University. His main research interests include the integrated modeling of data-driven approaches and machine learning for applications in new-type power system.