

文章编号: 1006-2467(2022)04-0413-09

DOI: 10.16183/j.cnki.jsjtu.2021.345

# 基于证据推理规则 CS-SVR 模型的 锂离子电池 SOH 估算

徐宏东<sup>1</sup>, 高海波<sup>1</sup>, 徐晓滨<sup>2</sup>, 林治国<sup>1</sup>, 盛晨兴<sup>1</sup>

(1. 武汉理工大学 能源与动力工程学院, 武汉 430063;

2. 杭州电子科技大学 自动化学院, 杭州 310018)

**摘 要:** 锂离子电池健康状态(SOH)的准确性影响电池的安全性和使用寿命. 针对锂离子电池 SOH 估算问题, 提出一种基于证据推理(ER)规则的布谷鸟搜索支持向量回归(CS-SVR)的 SOH 估算模型, 并利用 NASA Ames 研究中心的锂离子电池数据集进行 SOH 估算试验. 该方法以电池放电循环的平均放电电压和平均放电温度为模型输入, 利用 ER 规则进行推理, 得到输入数据的融合信度矩阵. 将该矩阵输入 CS 算法优化的 SVR 模型得到电池 SOH 估算结果. 结果表明, 与 5 种估算效果较好的现有模型相比, 基于 ER 规则的 CS-SVR 模型具有更良好的估算性能.

**关键词:** 锂离子电池; 证据推理规则; 布谷鸟搜索; 健康状态估算; 支持向量回归

中图分类号: TM 912.9

文献标志码: A

## State of Health Estimation of Lithium-ion Battery Using a CS-SVR Model Based on Evidence Reasoning Rule

XU Hongdong<sup>1</sup>, GAO Haibo<sup>1</sup>, XU Xiaobin<sup>2</sup>, LIN Zhiguo<sup>1</sup>, SHENG Chenxing<sup>1</sup>

(1. School of Energy and Power Engineering, Wuhan University of Technology,

Wuhan 430063, China; 2. Institute of System Science and Control Engineering,

Hangzhou Dianzi University, Hangzhou 310018, China)

**Abstract:** The state of health (SOH) estimation accuracy of lithium-ion battery affects the safety and service life of batteries. Aimed at the problem in SOH estimation of lithium-ion battery, a cuckoo search support vector regression (CS-SVR) model based on the evidence reasoning (ER) rule was proposed for SOH estimation. The lithium-ion battery data from NASA Ames Center was used to perform the SOH estimation test. In this method, the average voltage and average temperature of battery discharge cycles were taken as model input, and a fusion belief degree matrix of input data was obtained by the ER rule. The SOH estimation result of the battery was obtained by inputting a fusion belief degree matrix into the SVR model optimized by the CS algorithm. The results show that the CS-SVR algorithm based on the ER rule has a better estimation performance than the five existing models.

**Key words:** lithium-ion battery; evidence reasoning (ER) rule; cuckoo search (CS); state of health (SOH) estimation; support vector regression (SVR)

收稿日期: 2021-09-13

基金项目: 国家自然科学基金项目(U1709215), 国家水运安全工程技术研究中心开放基金(A2019003), 新能源船舶设计研发及应用示范关键技术研究(19DZ1203100)

作者简介: 徐宏东(1995-), 男, 山东省日照市人, 硕士生, 从事船舶电力推进健康状态管理研究.

通信作者: 高海波, 男, 副教授, 电话(Tel.): 13237187053; E-mail: hbgao\_whut@126.com.

锂离子电池作为重要的储能设备,在能量密度、使用寿命和安全性等方面具有优势,并在汽车、船舶和航天器等动力机械领域应用广泛<sup>[1-2]</sup>.作为储能式动力系统的核心部分,锂离子电池的健康状态(State of Health, SOH)是系统稳定运行的关键指标,因此有必要对其进行有效监测,保障系统的安全性和可靠性<sup>[3]</sup>.

电池 SOH 会随着充放电次数的增加而变差,通常利用电池容量的衰退来表征<sup>[4]</sup>.目前,锂离子电池 SOH 估算主要包括构建物理模型和数据驱动两种方法.锂离子电池内部反应机理以及基于物理模型的方法较为复杂,因此难以准确辨识模型参数,并在电池管理系统(Battery Management System, BMS)中进行实际应用<sup>[5]</sup>.而基于数据驱动的方法能够通过将锂离子电池 SOH 估算归纳为回归预测问题,建立监测参数与 SOH 的非线性关系,从而准确估算锂离子电池 SOH,比基于物理模型的方法更适用.目前,已有许多研究通过基于数据驱动的算法进行锂离子电池 SOH 估算<sup>[6]</sup>.其中,基于机器学习算法的支持向量回归(Support Vector Regression, SVR)和基于深度学习的人工神经网络法最常用<sup>[7-9]</sup>.Chang 等<sup>[10]</sup>采用带遗传算法的小波神经网络估算锂离子电池 SOH. Cheng 等<sup>[11]</sup>结合经验模式分解与反向传播的长短期记忆神经网络估计锂离子电池 SOH.但神经网络等方法需要利用大量数据才能够获得理想效果,不一定适用于小样本情况,并且其估算速度慢,难以保证模型对过拟合等问题的泛化能力.

相比于其他算法,机器学习算法中的 SVR 具有收敛速度快和泛化能力强的特点,适应于解决非线性问题和小样本问题,能够有效进行 SOH 估算<sup>[12-13]</sup>.Ng 等<sup>[14]</sup>提出一种基于朴素贝叶斯支持向量回归的组合算法来预测剩余电池寿命. Wei 等<sup>[15]</sup>采用粒子过滤器和 SVR 对锂离子电池 SOH 进行诊断.随着数据驱动方法的不断进步,需要寻找新算法以不断提升锂离子电池 SOH 估算的精度.然而,已有研究并没有解决测量数据中不确定信息对模型精度的影响,且鲁棒性差.

证据推理(Evidence Reasoning, ER)规则是一种基于数据驱动的新算法,可以利用数据统计和似然归一化法处理输入模型的不确定性信息,提取和融合输入变量与输出变量之间的证据,并根据证据进行决策分析,解决回归预测等问题.目前,其在故障识别和疾病诊断等领域应用广泛<sup>[16]</sup>. Xu 等<sup>[17]</sup>提出一种基于 ER 规则的动态系统状态估计方法. Gao

等<sup>[18]</sup>提出一种基于 ER 规则的极端海况船舶抗过旋控制方法.基于以上研究,本文提出一种 ER 规则和 SVR 相结合的 SOH 估算模型,利用 ER 规则的信息提取能力,提取并融合数据中的证据信息获取融合信度矩阵,并将其输入经布谷鸟搜索(Cuckoo Search, CS)优化的 SVR 模型,输出 SOH 估算结果,提升估算精度.模型性能测试采用 NASA Ames 研究中心的公开数据集,并与效果较好的模型进行对比,证明模型估算的准确性.

## 1 基于 CS-SVR 的 SOH 估算模型

SVR 的模型参数对性能具有重要影响,而模型参数通常由随机选择或人为代入验证确定,易导致模型精度不佳<sup>[19]</sup>.对此,建立基于 CS-SVR 的 SOH 估算模型,利用 CS 算法对 SVR 模型进行参数优化,提高模型精度.

### 1.1 支持向量回归

SVR 具有强大的非线性处理能力<sup>[20-21]</sup>,其回归函数建立如下:

$$f(\mathbf{x}) = \boldsymbol{\omega} \Phi(\mathbf{x}) + \mathbf{b} \quad (1)$$

式中:  $\mathbf{x}$  为输入;  $f(\mathbf{x})$  为输出;  $\boldsymbol{\omega}$  为权重;  $\Phi(\mathbf{x})$  为映射函数;  $\mathbf{b}$  为偏差.

建立最小化函数:

$$\min \left[ \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \right] \quad (2)$$

s. t.

$$y_i - \boldsymbol{\omega}_i x_i - b_i \leq \epsilon + \xi_i$$

$$\boldsymbol{\omega}_i x_i + b_i - y_i \leq \epsilon + \xi_i^*$$

$$\xi_i, \xi_i^* \geq 0$$

式中:  $C$  为惩罚因子;  $\xi_i$  和  $\xi_i^*$  为松弛变量;  $y_i$ 、 $x_i$ 、 $\boldsymbol{\omega}_i$  和  $b_i$  分别为个体  $i$  的输出值、输入值、权重和偏差;  $\epsilon$  为不敏感损失系数.引入核函数  $K(\mathbf{x}_M, \mathbf{x}_N)$ ,将模型的输入从低维向高维映射,以提升模型的非线性处理能力.其中,高斯径向基函数(RBF)是较为常用的核函数,表示如下:

$$K(\mathbf{x}_M, \mathbf{x}_N) = \exp \left( - \frac{\|\mathbf{x}_M - \mathbf{x}_N\|^2}{\gamma^2} \right) \quad (3)$$

式中:  $\mathbf{x}_M$  和  $\mathbf{x}_N$  分别为训练集和测试集的输入变量;  $\gamma$  为核函数参数,表示 RBF 核的半径.

### 1.2 布谷鸟搜索

CS 是一种基于布谷鸟寄生行为的新型仿生优化算法<sup>[22]</sup>,其利用全局游走结合局部随机游走的方式进行寻优,能够较好地解决优化问题<sup>[23]</sup>.CS 通过全局游走进行种群更新,该分布方式为<sup>[24]</sup>

$$x_i^{t+1} = x_i^t + \alpha L(\lambda) \quad (4)$$

式中:  $x_i^{t+1}$  为个体更新后的位置;  $x_i^t$  为第  $i$  个体第  $t$  代的位置;  $\alpha$  为步长因子;  $\lambda$  为 Lévy 指数;  $L(\lambda)$  为随机搜索步长, 路径服从 Lévy 飞行路径, 描述为

$$L(\lambda) = \frac{\mu}{|\nu|^{\frac{1}{\lambda}}} \tag{5}$$

式中:  $\mu$  和  $\nu$  为随机数. CS 选择部分个体, 通过满足 Lévy 飞行的搜索路径进行更新, 完成局部随机游走.

按照上述方式进行迭代, 当达到最大迭代次数时, 优化完成.

1.3 CS-SVR 模型

SVR 模型的性能受参数影响较大. 在 SOH 估算领域中, 参数优化算法与 SVR 的组合模型普遍应用于 SOH 估算研究. 本文利用 CS 对 SVR 的参数  $C$  和  $\gamma$  进行优化, 提升 SVR 模型性能, 模型流程如图 1 所示.

利用均方误差 (Mean-Square Error, MSE) 评价 SVR 模型的适应度:

$$MSE = \frac{\sum_{i=1}^n (Y_i - Y'_i)^2}{n} \tag{6}$$

式中:  $Y_i$  和  $Y'_i$  分别为第  $i$  个数据的实际值和估算值;  $n$  为数据个数. MSE 值越接近 0, 则估算值与实

际值的偏差越小, 模型的性能越好.

根据图 1 所示流程, 简述 CS-SVR 步骤: ①将数据按照一定比例划分为训练集和测试集; ②初始化 SVR 模型, 通过训练集完成模型拟合, 并获取对应的适应度 MSE; ③CS 通过更新搜索路径完成种群迭代, 保留其中的优势个体; ④迭代至设定代数后, 将最优解对应的  $C$  和  $\gamma$  作为 SVR 的参数, 得到最终模型.

2 数据来源与模型分析

2.1 锂离子电池数据

利用 NASA Ames 中心的数据集进行研究<sup>[25]</sup>. 在 24 ℃ 下, 对 18650 型号的 4 个锂离子电池 (B5、B6、B7 和 B18) 不断进行充放电循环得到该数据集. 电池充电循环过程为以 1.5 A 恒流开始充电, 直至电池电压上升至 4.2 V; 然后转为 4.2 V 恒压充电, 电池电流不断下降至 20 mA 后结束充电循环. 电池放电循环过程为以 2 A 恒流开始放电, 当 4 组电池的电压分别下降至截止电压 2.7、2.5、2.2、2.5 V 时, 结束放电循环, 并测量得到电池容量. 本文利用电池容量描述电池的 SOH:

$$SOH = C_i / C_0 \tag{7}$$

式中:  $C_i$  和  $C_0$  分别为电池的当前容量和初始容量. 随着循环的不断进行, 电池会加速老化. 设置试验终止条件为电池容量损失大于 30%, 即  $SOH < 70\%$ . 数据集中电池的 SOH 值如图 2 所示, 其中  $N_c$  为循环数.




图 2 电池的 SOH 曲线  
Fig. 2 SOH curves of batteries

可知, 随着循环次数增加, 电池的 SOH 呈现不断下降的趋势, 但是容量再生等原因会导致 SOH 曲线出现局部波动现象<sup>[26]</sup>, 因此往往难以实现 SOH 的准确估算. 其中, B5 和 B7 的 SOH 值多大于 70%, 本文将针对这两个电池的数据进行研究. 在老化试验中, B5 和 B7 的充放电循环次数均为 168 次. 将电池的每个放电过程作为一个样本, 则两个电池

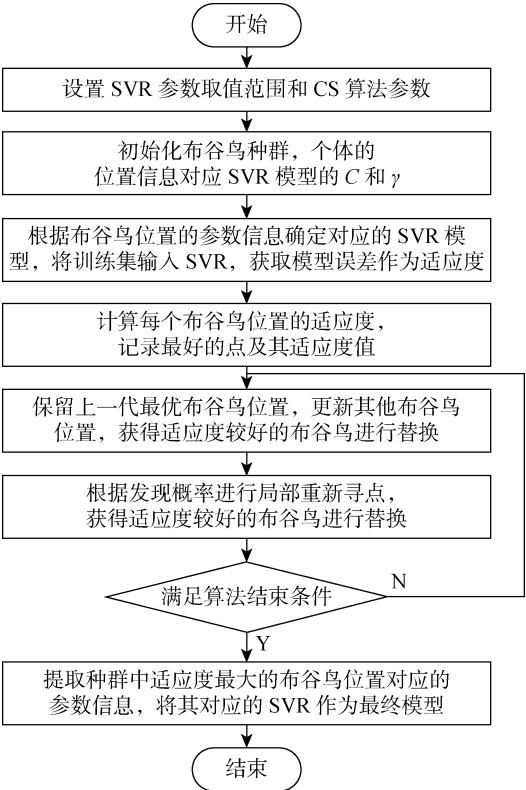


图 1 CS-SVR 流程图  
Fig. 1 Flow chart of CS-SVR

分别有 168 组数据. 建立该典型小样本数据集的样本集:

$$S = \{[h_V(t) \ h_T(t) \ I(t)] \mid t = 1, 2, \dots, T_S\}$$

其中:  $[h_V(t) \ h_T(t) \ I(t)]$  为样本集的一个样本向量;  $T_S$  为循环次数, 且  $T_S = 168$ . 将  $h_V(t)$  和  $h_T(t)$  作为样本特征值, 其分别表示电池在第  $t$  次放电过程中电压和温度的平均值, 且

$$h_V(t) = \frac{\sum_{i=1}^n u_i^t}{n_V} \quad (8)$$

式中:  $u_i^t$  为第  $t$  次放电过程中采集到的第  $i$  个电压数据;  $n_V$  为第  $i$  次放电过程中采集到的电压数据个数. 将式(8)中的  $u_i^t$  换为温度变量, 可以计算得到  $h_T(t)$ . 经过上述过程计算得到每个循环放电过程中的  $h_V(t)$  和  $h_T(t)$  值, 即完成特征值的提取. 将  $h_V(t)$  和  $h_T(t)$  归一化处理以防止不同数据维度对试验的影响.  $I(t)$  为放电结束后电池的 SOH. 将其作为样本的标签值, 并利用该样本验证模型在小样本数据集情况下的性能.

## 2.2 CS-SVR 模型分析

对构建的 CS-SVR 模型进行性能测试. 以 B5 为研究对象, 从 168 组数据中随机选取训练样本  $S_R = \{[h_V(t) \ h_T(t) \ I(t)] \mid t = 1, 2, \dots, T_{S_R}\}$ , 样本个数  $T_{S_R} = 100$ ; 剩余样本数据作为测试样本  $S_E = \{[h_V(t) \ h_T(t) \ I(t)] \mid t = 1, 2, \dots, T_{S_E}\}$ , 样本个数  $T_{S_E} = 68$ .

设定 SVR 模型参数的优化区间分别为  $C \in [2^{-5}, 2^{15}]$  和  $\gamma \in [2^{-15}, 2^3]$ ; CS 算法的初始种群数为 25,  $\lambda = 1.5$ , 发现概率  $P = 0.25$ ,  $\alpha = 1$ . 算法终止条件为迭代次数达到 100. 对 1.3 节中确定的 CS-SVR 模型进行训练和测试, 当迭代次数达到 100 后, 参数的优化方案为  $C = 32\ 654.152\ 5$ ,  $\gamma = 7.882\ 2$ . CS-SVR 模型在测试集上的估算输出结果如图 3 所示, 所得均方误差  $MSE_1 = 1.865\ 5$ .

将 CS-SVR 模型与未经参数优化的初始 SVR (Initial SVR, I-SVR) 模型对比. 其中, I-SVR 的模型参数由 Python 中 Scikit-learn 库的 SVR 函数默认确定<sup>[27]</sup>. 得到 I-SVR 模型在测试集上的估算误差  $MSE_2 = 2.759\ 0 > MSE_1$ .

两模型的测试结果对比如图 4 所示. 可知, 相比于 CS-SVR 模型, I-SVR 模型的估算结果整体偏离程度较大, 估算误差也较高. 表明模型参数经 CS 算法优化后, SVR 模型的估算性能有效提升. 但是在循环区间 0—10 和 43—46 内, 仍有部分估计值与真实值存在较大偏差.




图 3 测试数据与 CS-SVR 模型输出数据  
Fig. 3 Test data and output of CS-SVR model




图 4 CS-SVR 模型与 I-SVR 模型数据对比  
Fig. 4 Comparison of CS-SVR model and I-SVR model

## 3 基于 ER 规则 CS-SVR 的 SOH 估算模型

CS-SVR 直接将运行过程中测量到的电压、温度或其他量作为模型的输入, 易受到测量误差等因素的干扰, 导致估算偏差较大, 影响模型精度. 对此, 构建基于 ER 规则的 CS-SVR 模型. 首先利用 ER 规则处理输入数据的不确定性信息, 得到输入数据的融合信度矩阵, 以此挖掘原生数据中有价值的信息以降低误差干扰; 然后将融合信度矩阵作为 SVR 模型输入, 输出锂离子电池 SOH 的估算值, 进一步提升估算精度.

### 3.1 ER 规则

ER 规则能够结合证据的可靠性和权重对提取的证据进行融合, 原理概述如下<sup>[16, 28-29]</sup>.

假设集合  $\Theta = \{\theta_1, \theta_2, \dots, \theta_N\}$  包含所有假设, 并且两两互斥, 则该集合可以被定义为辨识框架.  $P(\theta)$  或  $2^\Theta$  表示包含  $\Theta$  所有子式的幂集. 单条证据可以表示为

$$e_j = \{(\theta, p_{\theta, j}) \mid \forall \theta \subseteq \Theta, \sum_{\theta \subseteq \Theta} p_{\theta, j} = 1\} \quad (9)$$

式中:  $p_{\theta, j}$  为假设  $\theta$  的证据支持度.

综合证据的权重  $\omega_j$  和可靠性  $r_j$  得到的信度分布为:

$m_j = \{(\theta, \tilde{m}_{\theta, j}) \mid \forall \theta \subseteq \Theta; (P(\Theta), \tilde{m}_{P(\Theta), j})\}$  (10)

式中:  $(\theta, \tilde{m}_{\theta, j})$  为  $m_j$  的元素,表示考虑  $\omega_j$  和  $r_j$  的情况下,  $\theta$  得到  $e_j$  支持的程度为  $\tilde{m}_{\theta, j}$ , 且

$$\tilde{m}_{\theta, j} = \begin{cases} 0, & \theta = \emptyset \\ c_{rw, j} m_{\theta, j}, & \theta \subseteq \Theta, \theta \neq \emptyset \\ c_{rw, j} (1 - r_j), & \theta = P(\Theta) \end{cases} \quad (11)$$

式中:  $m_{\theta, j} = \omega_j p_{\theta, j}$ ;  $c_{rw, j}$  为归一化因子,表示为  $c_{rw, j} = 1/(1 + \omega_j - r_j)$

则有

$$\sum_{\theta \subseteq \Theta} p_{\theta, j} = 1, \quad \sum_{\theta \subseteq \Theta} \tilde{m}_{\theta, j} + \tilde{m}_{P(\Theta), j} = 1$$

成立.

假设  $e_1$  和  $e_2$  为两组独立的证据,则 ER 规则结合证据的方式为

$$p_{\theta, e(2)} = \left\{ \begin{aligned} &0, && \theta = \emptyset \\ &\frac{\hat{m}_{\theta, e(2)}}{\sum_{D \subseteq \Theta} \hat{m}_{D, e(2)}}, && \theta \subseteq \Theta, \theta \neq \emptyset \end{aligned} \right\} \quad (12)$$
  
$$\hat{m}_{\theta, e(2)} = [(1 - r_2)m_{\theta, 1} + (1 - r_1)m_{\theta, 2}] + \sum_{B \cap C = \theta} m_{B, 1} m_{C, 2}, \quad \forall \theta \subseteq \Theta$$

式中:  $e(2)$  表示对证据  $e_1$  和  $e_2$  进行拟合;  $B, C$  和  $D$  为集合  $\Theta$  中的假设.通过递归的方式,式(12)可适用于多条证据的情况.

3.2 基于 ER 规则的 CS-SVR 估算模型

基于 ER 规则 CS-SVR 的估算模型利用 ER 规则从输入数据中提取证据并融合得到融合信度矩阵,再将其输入 CS-SVR 模型得到估算结果.假设用于估算的锂离子电池样本集为  $S' = \{[h_1(t) \ h_2(t) \ I(t)] \mid t = 1, 2, \cdots, T_s\}$ ,其中  $h_i(t) (i = 1, 2)$  为输入.详细建模过程如下.

首先,设定集合  $A_i = \{A_j^i \mid j = 1, 2, \cdots, J_i; i = 1, 2\}$  和  $D = \{D_n \mid n = 1, 2, \cdots, N\}$  分别为  $h_i(t)$  和  $I(t)$  的参考值集合.其中  $J_i$  和  $N$  分别为参考值  $A_j^i$  和  $D_n$  的个数.

其次,  $h_i(t)$  和  $I(t)$  均可以根据其参考值转化为相似度分布的形式:

$$S_1(h_i(t)) = \{(A_j^i, \alpha_{i, j}) \mid j = 1, 2, \cdots, J_i; i = 1, 2\} \quad (13)$$

式中:  $\alpha_{i, j}$  为  $h_i(t)$  匹配  $A_j^i$  的相似度,且

$$\alpha_{i, j} = \frac{A_{j+1}^i - h_i(t)}{A_{j+1}^i - A_j^i}, \quad \alpha_{i, j+1} = 1 - \alpha_{i, j}$$
  
$$A_j^i \leq h_i(t) \leq A_{j+1}^i$$
  
$$\alpha_{i, j'} = 0 \quad j' = 1, 2, \cdots, J_i; j' \neq j, j + 1$$

类似的,根据  $D_n$  可以计算出  $I(t)$  的相似度分布:

$$S_0(I(t)) = \{(D_n, \gamma_n) \mid n = 1, 2, \cdots, N\} \quad (14)$$

式中:  $\gamma_n$  为  $I(t)$  匹配  $D_n$  的相似度,且

$$\gamma_n = \frac{D_{n+1} - I(t)}{D_{n+1} - D_n}, \quad \gamma_{n+1} = 1 - \gamma_n$$
  
$$D_n \leq I(t) \leq D_{n+1}$$
  
$$\gamma_{n'} = 0 \quad n' = 1, 2, \cdots, N; n' \neq n, n + 1$$

样本数据通过式(13)和式(14)计算得到的相似度分布为  $(\alpha_{i, j} \gamma_n, \alpha_{i, j+1} \gamma_n, \alpha_{i, j} \gamma_{n+1}, \alpha_{i, j+1} \gamma_{n+1})$ ,其中  $\alpha_{i, j} \gamma_n$  为综合相似度,表示样本对  $(h_i(t), I(t))$  中  $h_i(t)$  和  $I(t)$  相似度的乘积.统计所有数据的综合相似度,得到投点结果如表 1 所示.其中,  $a_{n, j}$  为  $\alpha_{i, j} \gamma_n$  的和,且  $\delta_n = \sum_{j=1}^{J_i} a_{n, j}, \eta_j = \sum_{n=1}^N a_{n, j}, \sum_{n=1}^N \delta_n = \sum_{j=1}^{J_i} \eta_j = T_s$ .

表 1 样本对  $(h_i(t), I(t))$  的投点矩阵  
Tab. 1 Casting results of  $(h_i(t), I(t))$

$I(t)$	$h_i(t)$					总计
	$A_1^i$	$\cdots$	$A_j^i$	$\cdots$	$A_{J_i}^i$	
$D_1$	$a_{1, 1}$	$\cdots$	$a_{1, j}$	$\cdots$	$a_{1, J_i}$	$\delta_1$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$D_n$	$a_{n, 1}$	$\cdots$	$a_{n, j}$	$\cdots$	$a_{n, J_i}$	$\delta_n$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$D_N$	$a_{N, 1}$	$\cdots$	$a_{N, j}$	$\cdots$	$a_{N, J_i}$	$\delta_N$
总计	$\eta_1$	$\cdots$	$\eta_j$	$\cdots$	$\eta_{J_i}$	$T_s$

根据表 1,证据  $e_j^i$  的信度可以利用下式计算:

$$\beta_{n, j}^i = \frac{a_{n, j} \delta_n^{-1}}{\sum_{k=1}^N (a_{k, j} \delta_k^{-1})} \quad (15)$$

并有  $\sum_{n=1}^N \beta_{n, j}^i = 1$ ,则可定义对应于  $A_j^i$  的证据为  $e_j^i = (\beta_{1, j}^i, \beta_{2, j}^i, \cdots, \beta_{N, j}^i)$  (16)

因此,描述  $h_i(t)$  和  $I(t)$  之间关系的证据矩阵如表 2 所示.

表 2 样本对  $(h_i(t), I(t))$  的证据矩阵表  
Tab. 2 Evidence matrix of  $(h_i(t), I(t))$

$I(t)$	$h_i(t)$				
	$e_1^i$	$\cdots$	$e_j^i$	$\cdots$	$e_{J_i}^i$
	$A_1^i$	$\cdots$	$A_j^i$	$\cdots$	$A_{J_i}^i$
$D_1$	$\beta_{1, 1}^i$	$\cdots$	$\beta_{1, j}^i$	$\cdots$	$\beta_{1, J_i}^i$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$D_n$	$\beta_{n, 1}^i$	$\cdots$	$\beta_{n, j}^i$	$\cdots$	$\beta_{n, J_i}^i$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$D_N$	$\beta_{N, 1}^i$	$\cdots$	$\beta_{N, j}^i$	$\cdots$	$\beta_{N, J_i}^i$

定义证据的可靠性和权重. 定义  $h_i(t)$  和  $I(t)$  的相对变化值为

$$\text{Ch}_i(t) = \frac{h_i(t)}{\max_{t, t \in \{1, 2, \dots, T_S\}} (h_i(t))} \quad (17)$$

$$\text{CI}(t) = \frac{I(t)}{\max_{t, t \in \{1, 2, \dots, T_S\}} (I(t))} \quad (18)$$

获取  $h_i(t)$  和  $I(t)$  变化趋势的评价因子

$$\text{ah}_i = \sum_{t=1}^{T_S} |\text{CI}(t) - \text{Ch}_i(t)| \quad (19)$$

$h_i(t)$  的可靠性因子为

$$r_i = \frac{\min_{k, k \in \{1, 2\}} (\text{ah}_k)}{\text{ah}_i} \quad (20)$$

样本对中的  $h_i(t)$  会落入由两个临近参考值构成的参考值区间  $[A_j^i, A_{j+1}^i]$ , 则  $h_i(t)$  的证据可由参考值证据  $e_j^i$  和  $e_{j+1}^i$  以加权的形式获得:

$$e_i = \{(D_n, p_{n,i}), n = 1, 2, \dots, N\} \quad (21)$$

式中:

$$p_{n,i} = \alpha_{i,j} \beta_{n,j}^i + \alpha_{i,j+1} \beta_{n,j+1}^i \quad (22)$$

最后, 利用 3.1 节中的 ER 规则可以将上式计算得到的证据进行融合, 证据的初始权重设为  $w_i = r_i$ , 得到融合结果:

$$O(F(t)) = \{(D_n, p_{n,e(2)}), n = 1, 2, \dots, N\} \quad (23)$$

估计锂离子电池 SOH 值:

$$\hat{I}(t) = \sum_{n=1}^N D_n p_{n,e(2)} \quad (24)$$

在 ER 规则模型中, 通常利用式 (24) 将  $I(t)$  与融合信度相乘来获取估算值, 但这种线性处理方法难以保证 SOH 估算的精度. 而 SVR 具有较好的非线性处理能力<sup>[17]</sup>, 能够集合 ER 规则和 SVR 的优点. 因此利用 SVR 处理由 ER 规则获取的融合信度矩阵

$$\mathbf{P}_{e(2)} = [p_{1,e(2)} \ p_{2,e(2)} \ \dots \ p_{N,e(2)}]$$

不仅能够从原生数据中提取有价值的信息, 减少误差干扰, 提升 SVR 模型的估算性能, 还能够提高估算精度.

## 4 试验结果

采用 2.2 节中的试验条件和训练样本, 先以 B5 为研究对象, 测试 ER-CS-SVR 模型的估算性能. 利用 ER 规则模型, 分别得到  $S_R$  和  $S_E$  的融合信度矩阵  $\mathbf{P}_{e(2)}^R$  和  $\mathbf{P}_{e(2)}^E$ , 并将其作为 CS-SVR 模型的输入. 迭代 100 次后, 得到参数优化方案为  $C=32\ 768$ ,  $\gamma=0.000\ 9$ , 并得到 ER-CS-SVR 模型的测试输出结果 (见图 5), 其均方误差  $\text{MSE}_3 (=1.048\ 3) <$




图 5 测试数据与 ER-CS-SVR 模型输出数据

Fig. 5 Test data and output of ER-CS-SVR model

$\text{MSE}_1$ , 表明与 CS-SVR 模型相比, ER-CS-SVR 模型能够更好地进行 SOH 估算.

为了进一步分析模型的估算效果, 对比两个模型在测试集上的 SOH 估算结果, 如图 6 所示. 可知, 两个模型均能够较好地进行 SOH 估算. 与 CS-SVR 模型相比, ER-CS-SVR 模型的估算输出在大部分情况下更贴近于 SOH 的真实值, 特别是在 1—10 和 45—51 的样本区间内, ER-CS-SVR 模型可以有效降低估计输出的波动, 使得 ER-CS-SVR 模型 MSE 较小. 这是因为基于数据统计和似然归一化的 ER 规则可以将输入数据转化为融合置信度矩阵的形式来处理数据中的不确定性信息, 从而减少数据中的误差干扰和 SVR 模型波动. 但是在 3—6 的样本区间内, ER-CS-SVR 模型与实际值之间的误差较大, 这是因为测量误差或运行环境剧烈变化导致个别离群值出现, 且在小样本情况下, 训练数据较少, 更易产生较大偏差. 但图 6 中个别离群值的拟合




图 6 CS-SVR 模型与 ER-CS-SVR 模型数据对比

Fig. 6 Comparison of ER model and ER-CS-SVR model



效果不佳并不影响模型整体的估算性能,从而进一步证明了模型的可靠性.

为了进一步验证模型的性能,在 B5 和 B7 两组 NASA 锂离子电池数据集上,对比 I-SVR、CS-SVR、ER-CS-SVR 与现有估算性能较好的遗传算法(GA)和粒子群(PSO)优化的 SVR 模型,以及误差反向传播神经网络(BP-NN)模型的估算性能.数据集划分固定不变,同时将相关系数作为评估标准:




图 7 不同模型估算结果对比  
Fig. 7 Estimation results of different models

表 3 不同模型估算性能对比  
Tab. 3 Estimation performances of different models

电池编号	评估标准	I-SVR	BP-NN	GA-SVR	PSO-SVR	CS-SVR	ER-CS-SVR
B5	MSE	2.759 0	1.925 9	1.876 4	1.869 2	1.865 5	1.048 3
	R <sup>2</sup>	0.973 6	0.980 7	0.982 0	0.982 1	0.982 1	0.990 0
B7	MSE	3.411 6	2.155 1	1.309 3	1.303 4	1.301 9	1.157 0
	R <sup>2</sup>	0.954 8	0.973 0	0.982 6	0.982 7	0.982 7	0.984 7

由图 7 和表 3 可知,各模型在不同数据集上的估算结果存在差异,但整体趋势相同.与 GA 和 PSO 算法相比,经 CS 算法优化的 SVR 模型,其 MSE 值最小,R<sup>2</sup> 值最大,表明 CS 能够更好地优化 SVR 模型参数,减小模型误差,提升 SVR 模型的非线性拟合能力,是一种有效的参数优化算法.表 3 中 ER-CS-SVR 模型的 MSE 值最小,R<sup>2</sup> 值最大;图 7 中 ER-CS-SVR 模型的估算曲线更贴近于真实值,表明 ER-CS-SVR 的联合模型比单一结合 CS 等优化算法的 SVR 模型具有更好的估算性能.此外,与 BP 模型相比,ER-CS-SVR 模型在小样本条件下能够表现出更好的估算效果.这是由于 ER-CS-SVR 结合了 ER 规则能够处理不确定信息的能力和 CS-SVR 能够解决非线性小样本问题的能力.

数据集划分方式可能对试验结果产生影响,简单的交叉验证不能很好地反映模型之间的性能差

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - X'_i)^2}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

(25)

式中:  $X_i$  和  $X'_i$  为第  $i$  个样本的真实值和估算值; $\bar{X}$  为样本平均值.  $R^2$  表示估算值与真实值的相关性,其值越接近 1,相关性越大.各模型估算结果对比如图 7 所示,性能对比结果如表 3 所示.

异,因此利用 8 折交叉验证进一步评估性能对比结果.以 B5 为例,首先将样本集平均分为 8 份,其中 7 份作为训练集,1 份作为测试集.然后对 ER-CS-SVR 和 CS-SVR 模型进行 8 次循环测试,从而充分利用数据,得到可靠结论.最后分别得到 ER-CS-SVR 和 CS-SVR 模型的 8 个测试样本的 MSE 平均值为  $\overline{\text{MSE}}_3 (=1.497 6) < \overline{\text{MSE}}_1 (=1.960 2)$ ,进一步验证了 ER-CS-SVR 模型的有效性.

5 结论

本文以锂离子电池为研究对象,提出一种基于 ER 规则 CS-SVR 的锂离子电池 SOH 估算模型,联合 ER 规则和 CS-SVR 模型以提升模型的估算效果.利用 NASA Ames 研究中心的公开数据集,验证 ER-CS-SVR 模型的估算效果,并与其他模型进行进一步比较,结果表明:基于 ER 规则的 CS-SVR

模型具有较高的估计精度,优于单一的模型;在小样本数据的情况下,所提 ER-CS-SVR 模型可以充分融合 SVR 模型面对非线性、小样本时的泛化能力和 ER 规则的不确定性信息处理能力,具有较好的估算效果;对于不同电池数据集和不同数据集划分方法,ER-CS-SVR 均具有良好的估计性能.因此,在数据量少、需要快速估计 SOH 的应用场景中,ER-CS-SVR 模型可以快速准确地估计 SOH,为电池管理系统提供可靠的电池健康信息.总之,ER-CS-SVR 是一种有效的 SOH 估算模型,可以为电池安全提供有力支持.

## 参考文献:

- [1] MISYRIS G S, MARINOPOULOS A, DOUKAS D I, *et al.* On battery state estimation algorithms for electric ship applications[J]. **Electric Power Systems Research**, 2017, 151: 115-124.
- [2] XU D P, WANG L F, YANG J. Research on Li-ion battery management system[C]// **2010 International Conference on Electrical and Control Engineering**. Wuhan, China: IEEE, 2010: 4106-4109.
- [3] MA G J, YU C H, HE Z W, *et al.* Estimation of Li-ion battery SOH using Fletcher-Reeves based ANFIS [C]// **2015 IEEE 24th International Symposium on Industrial Electronics**. Buzios, Brazil: IEEE, 2015: 827-830.
- [4] LOTFI N, LI J, LANDERS R G, *et al.* Li-ion battery state of health estimation based on an improved single particle model [C] // **2017 American Control Conference**. Seattle, USA: IEEE, 2017: 86-91.
- [5] BERICIBAR M, GANDIAGA I, VILLARREAL I, *et al.* Critical review of state of health estimation methods of Li-ion batteries for real applications[J]. **Renewable and Sustainable Energy Reviews**, 2016, 56: 572-587.
- [6] 张新锋, 饶勇翔, 姚蒙蒙. 基于支持向量回归的锂电池健康状态估计[J]. **中北大学学报(自然科学版)**, 2019, 40(6): 511-516.  
ZHANG Xinfeng, RAO Yongxiang, YAO Mengmeng. Estimation of lithium battery state of health based on support vector regression[J]. **Journal of North University of China (Natural Science Edition)**, 2019, 40(6): 511-516.
- [7] QU J T, LIU F, MA Y X, *et al.* A neural-network-based method for RUL prediction and SOH monitoring of lithium-ion battery[J]. **IEEE Access**, 2019, 7: 87178-87191.
- [8] YANG D, WANG Y J, PAN R, *et al.* State-of-health estimation for the lithium-ion battery based on support vector regression[J]. **Applied Energy**, 2018, 227: 273-283.
- [9] ZENG M M, ZHANG P, YANG Y, *et al.* SOC and SOH joint estimation of the power batteries based on fuzzy unscented Kalman filtering algorithm[J]. **Energies**, 2019, 12(16): 3122.
- [10] CHANG C, WANG Q Y, JIANG J C, *et al.* Lithium-ion battery state of health estimation using the incremental capacity and wavelet neural networks with genetic algorithm[J]. **Journal of Energy Storage**, 2021, 38: 102570.
- [11] 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.
- [12] WENG C H, SUN J, PENG H E. Model parametrization and adaptation based on the invariance of support vectors with applications to battery state-of-health monitoring[J]. **IEEE Transactions on Vehicular Technology**, 2015, 64(9): 3908-3917.
- [13] 刘皓, 胡明昕, 朱一亨, 等. 基于遗传算法和支持向量回归的锂电池健康状态预测[J]. **南京理工大学学报**, 2018, 42(3): 329-334.  
LIU Hao, HU Mingxin, ZHU Yiheng, *et al.* Prediction for state of health of lithium-ion batteries by genetic algorithm and support vector regression[J]. **Journal of Nanjing University of Science and Technology**, 2018, 42(3): 329-334.
- [14] NG S S Y, XING Y J, TSUI K L. A naive Bayes model for robust remaining useful life prediction of lithium-ion battery[J]. **Applied Energy**, 2014, 118: 114-123.
- [15] WEI J W, DONG G Z, CHEN Z H. Remaining useful life prediction and state of health diagnosis for lithium-ion batteries using particle filter and support vector regression[J]. **IEEE Transactions on Industrial Electronics**, 2018, 65(7): 5634-5643.
- [16] XU X B, JIN Z, YANG J B, *et al.* Track irregularity fault identification based on evidence reasoning rule [C]// **2016 IEEE International Conference on Intelligent Rail Transportation**. Birmingham, UK: IEEE, 2016: 298-306.
- [17] XU X B, ZHANG Z, ZHENG J, *et al.* State estimation method based on evidential reasoning rule [C]// **2015 IEEE Advanced Information Technology, Electronic and Automation Control Conference**. Chongqing, China: IEEE, 2015: 610-617.



[18] GAO H B, LIAO L H, HE Y L, *et al.* Improved control of propeller ventilation using an evidence reasoning rule based Adaboost, M1 approach[J]. **Ocean Engineering**, 2020, 209: 107329.

[19] GHAZVINIAN H, MOUSAVI S F, KARAMI H, *et al.* Integrated support vector regression and an improved particle swarm optimization-based model for solar radiation prediction[J]. **PLoS One**, 2019, 14 (5): e0217634.

[20] YANG Y F, ZHANG M H, DAI Y W. A Fuzzy Comprehensive CS-SVR Model-based health status evaluation of radar[J]. **PLoS One**, 2019, 14 (3): e0213833.

[21] NI K S, NGUYEN T Q. Image superresolution using support vector regression[J]. **IEEE Transactions on Image Processing**, 2007, 16(6): 1596-1610.

[22] YANG X S, DEB S. Multiobjective cuckoo search for design optimization[J]. **Computers & Operations Research**, 2013, 40(6): 1616-1624.

[23] NARTU T R, MATTA M S, KORATANA S, *et al.* A fuzzified Pareto multiobjective cuckoo search algorithm for power losses minimization incorporating SVC[J]. **Soft Computing**, 2019, 23 (21): 10811-10820.

[24] CHENG J T, WANG L, XIONG Y. Ensemble of cuckoo search variants[J]. **Computers & Industrial Engineering**, 2019, 135: 299-313.

[25] SAHA B, GOEBEL K. Battery data set[R]. **California: NASA Ames Prognostics Data Repository**, 2007.

[26] QIN T C, ZENG S K, GUO J B. Robust prognostics for state of health estimation of lithium-ion batteries based on an improved PSO-SVR model[J]. **Microelectronics Reliability**, 2015, 55(9/10): 1280-1284.

[27] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, *et al.* Scikit-learn: Machine learning in Python [J]. **Journal of machine Learning Research**, 2011, 12: 2825-2830.

[28] ZHAO F J, ZHOU Z J, HU C H, *et al.* A new safety assessment method based on evidential reasoning rule with a prewarning function[J]. **IEEE Access**, 2018, 6: 31862-31871.

[29] LIAO L H, GAO H B, HE Y L, *et al.* Fault diagnosis of capacitance aging in DC link capacitors of voltage source inverters using evidence reasoning rule [J]. **Mathematical Problems in Engineering**, 2020, 2020: 1-12.

(本文编辑:孙伟)