

DOI:10.19651/j.cnki.emt.2211051

# 基于改进 GWO-SVR 的锂电池 SOH 估计<sup>\*</sup>

梁 杨<sup>1</sup> 周永军<sup>1</sup> 蒋淑霞<sup>1</sup> 袁晓文<sup>2</sup> 张 淳<sup>1</sup>

(1. 中南林业科技大学 机电工程学院 长沙 410000; 2. 贵州梅岭电源有限公司 遵义 563000)

**摘要:** 为了提高锂电池健康状态的估计精度,提出了一种基于 IGWO-SVR 的锂电池 SOH 估计方法。针对支持向量回归(SVR)内核参数选择的问题,采用改进灰狼(IGWO)算法优化支持向量回归的内核参数;选取合适的健康特征作为输入,电池 SOH 作为输出,建立 IGWO-SVR 估计模型,实现锂电池 SOH 的估计。基于 NASA 电池数据集,对该模型进行训练及验证,并与 SVR 和 GWO-SVR 方法相比。结果表明,IGWO-SVR 方法能有效提高 SOH 估计的精度和稳定性,最大估计误差不超过 2%。

**关键词:** 锂离子电池;健康状态;支持向量回归;改进灰狼算法

中图分类号: TM912 文献标识码: A 国家标准学科分类代码: 510.80

## Lithium battery SOH estimation based on improved GWO-SVR

Liang Yang<sup>1</sup> Zhou Yongjun<sup>1</sup> Jiang Shuxia<sup>1</sup> Yuan Xiaowen<sup>2</sup> Zhang Song<sup>1</sup>(1. College of Electromechanical Engineering, Central South University of Forestry and Technology, Changsha 410000, China;  
2. Guizhou MeiLing Power Sources Co., Ltd., Zunyi 563000, China)

**Abstract:** In order to improve the estimation accuracy of lithium battery state of health, a lithium battery SOH estimation method based on IGWO-SVR is proposed. Firstly, aiming at the problem of kernel parameter selection of support vector regression (SVR), the improved gray wolf (IGWO) algorithm is used to optimize the kernel parameters of support vector regression (SVR). The SVR estimation model realizes the estimation of the SOH of lithium batteries. Based on the NASA battery dataset, the model is trained and validated and compared with the SVR and GWO-SVR methods. The results show that the IGWO-SVR method can effectively improve the accuracy and stability of SOH estimation, and the maximum estimation error does not exceed 2%.

**Keywords:** Lithium battery; health status; support vector regression; improved grey wolf algorithm

## 0 引言

锂离子电池凭借比能量高、循环寿命长、自放电率低等优点被广泛应用于新能源汽车领域<sup>[1]</sup>。锂电池的健康状态(state of health, SOH)反映了电池的老化程度,准确估计其参数对延长电池的使用寿命和保证电池的可靠性具有重要意义。

SOH 估计方法主要可分为基于模型的方法和基于数据驱动的方法。基于模型的方法,针对不同型号、不同工况下的电池,需要重新建立模型,使用局限性较大<sup>[2]</sup>。基于数据驱动的方法,避免了物理建模,无需考虑电池内部复杂的化学反应过程<sup>[3]</sup>,因此国内外学者针对此方法进行了广泛的研究。

目前,基于数据驱动的方法主要有人工神经网络

(artificial neural network, ANN)<sup>[4-5]</sup>、支持向量机(support vector machine, SVM)<sup>[6]</sup>、高斯过程回归(Gaussian process regression, GPR)<sup>[7]</sup>。李强龙等<sup>[8]</sup>采用改进蚁狮优化和支持向量回归方法进行电池 SOH 估计,能稳定地估计 SOH 且估计精度较高;肖仁鑫等<sup>[9]</sup>通过蚁群算法对神经网络的输入参数进行优化,实现 SOH 的精确估计;Lin 等<sup>[10]</sup>通过提取健康特征,采用概率神经网络的方法进行 SOH 估计;Li 等<sup>[11]</sup>建立了高斯过程回归的 SOH 估计模型,提取 IC 曲线片段作为健康特征;Zhao 等<sup>[12]</sup>以充放电过程中等压降时间作为 SVR 算法的输入,提高了 SOH 估计模型的效率。

本文基于数据驱动的方法,提取能够表征电池老化的健康特征,介绍了改进的灰狼优化(improved grey wolf optimization, IGWO)算法和支持向量回归(support vector regression, SVR)算法,通过 IGWO 算法优化 SVR 模型的

收稿日期:2022-08-12

\*基金项目:湖南省自然科学基金(2019JJ60076)项目资助

参数,构建了基于健康特征的 IGWO-SVR 的 SOH 估计方法。最后,利用 NASA 的数据集对该方法进行训练和验证,经过对比分析证明了该方法能够准确地估计电池的 SOH。

## 1 IGWO-SVR 模型的建立

### 1.1 改进的灰狼优化算法

GWO 算法<sup>[13]</sup>是一种生物启发式智能算法,针对传统的 GWO 算法的收敛因子  $\alpha$  适应性较低和算法搜索过程中头狼为非最优解导致陷入局部最优的情况,本文采用改进的收敛因子和重选精英策略对传统的 GWO 算法进行改进。

#### 1) 收敛因子非线性调整

GWO 算法不断地更新迭代生成新的  $\alpha$ 、 $\beta$ 、 $\delta$  狼,狼群不断地接近猎物,直至完成捕猎,其中对猎物的攻击过程主要是通过收敛因子  $\alpha$  不断递减来完成,从而使收敛向量  $\mathbf{A}$  也在  $[-\alpha, \alpha]$  区间内变化。当  $|\mathbf{A}| < 1$  时,灰狼的下一个位置将接近猎物的位置,便于进行攻击;当  $|\mathbf{A}| > 1$  时,狼群则会继续搜寻猎物。因此,收敛因子  $\alpha$  的变化趋势对 GWO 算法的影响较大,传统 GWO 算法的收敛因子变化可定义为:

$$\alpha = 2 - \frac{2i}{i_{\max}} \quad (1)$$

针对收敛因子对 GWO 算法的重要影响,改进收敛因子变化趋势的公式如下式所示,收敛因子的变化的对比如图 1 所示。

$$\alpha = 2 \times \left(1 - \frac{i}{i_{\max}}\right)^{\frac{1}{2}} \quad (2)$$

式中: $i$  为当前迭代次数; $i_{\max}$  为最大迭代次数。

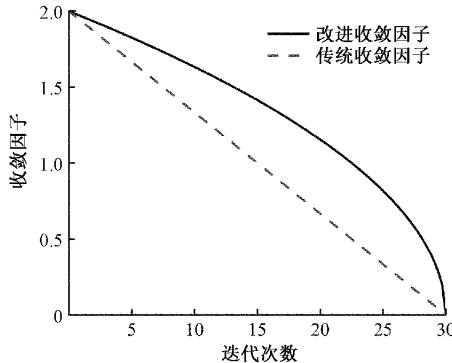


图 1 收敛因子对比

由图 1 可知,前期收敛因子降低的幅度不大,可使狼群具有较大的搜索范围,增加多样性;中后期收敛因子降低的幅度增大,可以加速灰狼捕获猎物,增加算法的收敛速度,能够提升寻优的有效性。

#### 2) 精英个体重选策略

GWO 算法中精英个体  $\alpha$ 、 $\beta$ 、 $\delta$  狼的更新,采用的是每次迭代后将当代狼群与前代  $\alpha$ 、 $\beta$ 、 $\delta$  狼作比较的方法,若种群中未出现优于这三匹狼的位置,种群将向其靠拢;若头狼

$\alpha$  陷入局部最小,这种方法将损失多样性,造成局部最优的现象。因此采用一种新的精英个体重选策略,即每次迭代后都在当代种群中选取适应度值排名前三的个体记录为新的  $\alpha$ 、 $\beta$ 、 $\delta$ ,而不是与上次迭代的  $\alpha$ 、 $\beta$ 、 $\delta$  相比较择优<sup>[14]</sup>,能够较好地保证种群的多样性,减少陷入局部最优的问题。

### 1.2 支持向量回归

SVR 方法在机械学习中应用广泛,常用来解决小样本、非线性问题<sup>[15]</sup>。假设给定样本集,  $M = \{\mathbf{X}_i, \mathbf{Y}_i\}_{i=1}^n (x_i \in \mathbf{X} = R^n, y_i \in \mathbf{Y} = R)$ ,  $\mathbf{X}$  为输入向量,  $\mathbf{Y}$  为对应的输出向量。SVR 方法原理是通过非线性映射将样本集从低维空间映射到高维空间。非线性映射可定义为:

$$f(x) = \omega \cdot \varphi(x) + b \quad (3)$$

式中: $\omega$  为权重; $x$  为输入数据; $b$  为截距。

$f(x)$  可等效为求最优解问题,可形式化为:

$$\frac{1}{2} \|\omega\|^2 + C \sum_i^n L(f(x_i), y_i) \quad (4)$$

式中: $C$  为惩罚因子; $L$  为损失函数。通过引入松弛变量  $\{\xi_i\}_1^n$  和  $\{\xi_i^*\}_1^n$ , 可得:

$$\min R(\omega, b, \xi) = \frac{1}{2} \|\omega\|^2 + C \sum_i^n L(f(x_i), y_i) \quad (5)$$

$$\begin{aligned} & \left\{ \begin{array}{l} y_i - \omega \cdot \varphi(x_i) - b \leq \epsilon + \xi_i, \\ \omega \cdot \varphi(x_i) + b - y_i \leq \epsilon + \xi_i^*, \\ \xi_i \geq 0, \xi_i^* \geq 0 \end{array} \right. \end{aligned} \quad (6)$$

式中: $\epsilon$  为最大损失误差, $\epsilon > 0$ 。引入拉格朗日乘数及核函数,利用对偶原理,将目标函数转换为对偶形式,如下:

$$\begin{aligned} \max R(\alpha_i^*, \alpha_i) &= -\frac{1}{2} \sum_{i,j}^n (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) \varphi(x_i) \varphi(x_j) - \sum_i^n \alpha_i (y_i + \epsilon) + \sum_i^n \alpha_i^* (y_i - \epsilon) \quad (7) \end{aligned}$$

$$\begin{aligned} & \left\{ \begin{array}{l} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C \end{array} \right. \end{aligned} \quad (8)$$

式中: $\alpha_i$  和  $\alpha_i^*$  为拉格朗日乘数, $i = 1, 2, \dots, n$ 。最小化拉格朗日函数后,获得非线性映射 SVR 表达式为:

$$f(x) = \sum_i^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (9)$$

式中: $K(x_i, x) = \varphi(x_i) \varphi(x)$  为核函数,SVR 常采用径向基函数(radial basis function, RBF)作为核函数,RBF 的定义为:

$$K_{RBF}(x_i, x) = \exp(-\frac{1}{2\sigma^2} \|x_i - x\|^2) \quad (10)$$

式中: $\sigma$  为核参数。

### 1.3 IGWO-SVR 方法

根据 1.2 所述 SVR 内容可知,惩罚因子和核参数对 SVR 方法的准确性具有关键性作用,可选择合适的智能优化算法确定参数  $c$  和  $\sigma$ 。因此,本文采用 IGWO 算法对  $c$

和  $\sigma$  进行寻优, 提高 SVR 模型的精度。

该方法的流程如图 2 所示, 主要步骤如下:

1) 数据处理: 按照选取的健康特征提取数据集中的数据, 并将处理完成的数据分成训练集和测试集;

2) 设置 IGWO 算法参数: 设置狼群数量  $SearchAgents\_no$ , 最大迭代数  $Max\_iteration$ , 变量数  $dim$ , 参数下界  $I_b$ , 参数上界  $u_b$ ;

3) 设置适应度函数: 使用实际 SOH 与估计 SOH 之间的均方差 (mean square error, MSE) 来建立适应度函数, 即:

$$MSE = \frac{1}{n} \sum_i^n (\hat{y}_i - y_i)^2 \quad (11)$$

式中:  $\hat{y}_i$  为第  $i$  次循环的预测 SOH;  $y_i$  为第  $i$  次循环的实际 SOH。

4) IGWO 算法优化 SVR 参数: 完成参数的初始化和函数的适应度之后, 通过 IGWO 算法的迭代, 优化 SVR 的输入参数  $c$  和  $\sigma$ ;

5) SVR 模型的建立: 将 IGWO 算法得到的参数  $c$  和  $\sigma$  代入 Matlab 的 LIBSVM 工具箱, 通过训练集对模型进行训练, 建立 SOH 估计模型;

6) 锂电池 SOH 的估计: 通过测试集验证已训练完成的 SVR 模型, 实现锂电池 SOH 的估计。

IGWO-SVR 估计电池 SOH 的算法流程如图 2 所示。

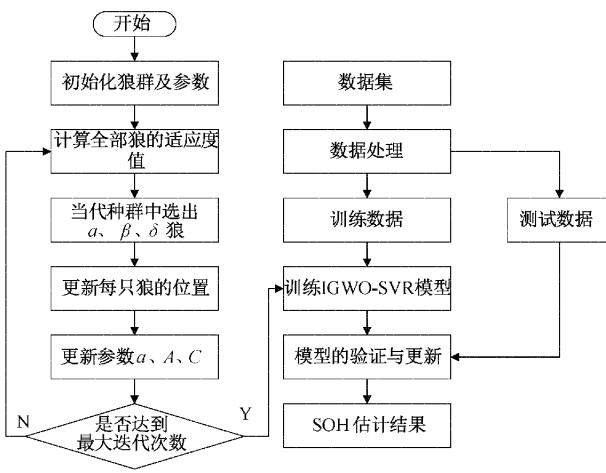


图 2 IGWO-SVR 算法流程

## 2 SOH 定义及特征提取

### 2.1 SOH 定义

本文选择当前可用容量与额定容量的比值<sup>[16]</sup> 定义 SOH, 定义式如下, 根据该定义计算 SOH 时需要了解电池的当前可用容量。

$$SOH = \frac{C_i}{C} \times 100\% \quad (12)$$

式中:  $C_i$  为当前可用容量;  $C$  为额定容量。

### 2.2 锂电池数据集

本文选用 NASA PCoE<sup>[17]</sup> 数据集, 该数据集提供了容量为 2 000 mAh 的 18650 锂电池的充放电老化试验数据。选取数据集中的 4 节锂电池, 分别为 B0005、B0006、B0007、B0018。老化试验在室温(24 ℃)环境下进行, 每个循环周期的包含充电和放电过程, 充电为恒流恒压模式, 放电以 1C 倍率进行恒流放电。具体步骤如下:

1) 充电过程: 对这四块电池以 1.5 A 的电流进行恒流充电, 直至电池电压达到 4.2 V, 再以 4.2 V 恒压模式进行充电, 直至充电电流降至 20 mA。

2) 放电过程: 以 1C 的放电倍率进行放电, 直至四节电池的电压分别降至 2.7、2.5、2.2、2.5 V 后停止放电。

按照上述步骤, 对电池进行循环充放电试验, 当电池的额定容量下降 30% 时, 即容量下降为 1 400 mAh, 试验停止。根据试验数据的容量变化和 SOH 定义公式, 得到 4 节电池的 SOH 变化曲线如图 3 所示。

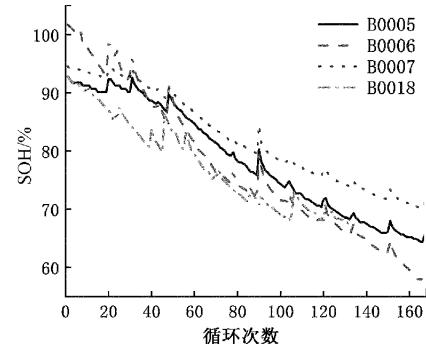


图 3 SOH 变化曲线

### 2.3 健康特征的提取和分析

电池的外特性数据能够反应电池的内部特征, 可以从电池的充放电数据中提取表征电池容量变化的参数, 这种用来表征电池内部特征的外特性参数被称为健康特征 (health feature, HF)<sup>[17]</sup>。健康特征的提取对 SOH 的估计精度具有重要意义, 本文根据所选的健康特征能够表征电池退化的原则, 采用直接参数法作为健康特征的选取方法, 即基于测试设备所能采集的电压、电流等参数, 选取充放电过程中能够表征电池退化的参数。健康特征通常为恒流恒压段时间、等时间段内电压变化、电压电流曲线最大斜率等, 本文所提取的健康特征分别为:

1) 恒流充电过程中的等压升时间, 即充电电压从 3.8 V 升至 4.2 V 所需的充电时间, 记作 HF1; 2) 恒压充电过程中的等流降时间, 即充电电流从 1.5 A 降低至 0.5 A 所需的充电时间, 记作 HF2; 3) 恒流放电过程中的等压降时间, 即放电电压从 3.8 V 降低至 3.5 V 所需的放电时间, 记作 HF3。

为验证健康特征的可行性, 本文采用 Pearson 相关性分析法<sup>[18]</sup> 进行分析, 假设两组数据分别为  $X = (X_1, X_2, \dots, X_n)$  和  $Y = (Y_1, Y_2, \dots, Y_n)$ , 该方法具体计算公式如

式(13)所示。

Pearson 相关系数:

$$\rho_{X,Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (13)$$

式中: $E$  表示期望,  $\rho_{X,Y}$  为  $X$  与  $Y$  之间的相关系数。

根据上述方法, 4 节电池所提取的健康特征与电池 SOH 之间的 Pearson 相关系数如表 1 所示。

表 1 健康特征与电池 SOH 间的相关系数

电池编号	Pearson 系数		
	HF1	HF2	HF3
B0005	0.995 6	0.995 5	0.999 9
B0006	0.999 9	0.999 9	0.990 2
B0007	0.999 7	0.999 5	0.994 8
B0018	0.999 8	0.999 9	0.973 5

Pearson 相关系数接近 1 或者 -1 为正向或者负向强相关性, 接近 0 则为无相关性。由表 1 可知, 3 个健康特征与电池 SOH 之间的相关系数均在(0.9~1), 说明健康特征与电池 SOH 具有很强的相关性。因此, 这 3 个健康特征可以较好的表征电池的 SOH。

### 3 基于 IGWO-SVR 的锂电池 SOH 估计

#### 3.1 评估标准

为了评估 IGWO-SVR 估计锂电池 SOH 的性能, 本文选取平均绝对误差(mean absolute error, MAE)和均方根误差(root-mean-square error, RMSE)作为评估标准。

1) SOH 估计误差(Error)

$$Error = \hat{y} - y \quad (14)$$

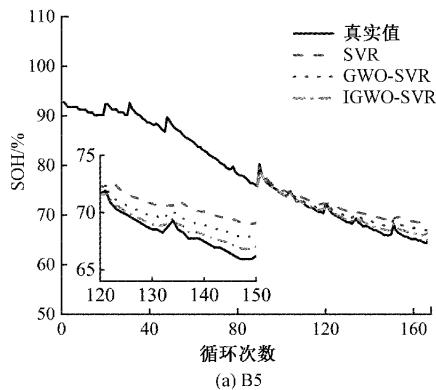
2) 平均绝对百分比误差(MAPE)

$$MAPE = \frac{1}{n} \sum_i^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (15)$$

3) 均方根误差(RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_i^n (\hat{y}_i - y_i)^2} \quad (16)$$

式中:  $\hat{y}$  是 SOH 估计值,  $y$  是实际 SOH。



#### 3.2 锂电池的 SOH 估计

本文基于 2.2 节所述数据集和 MATLAB2019b 平台对 IGWO-SVR 估方法进行实验验证, 分别选择 4 节电池的前 88 次循环周期作为训练样本, 其余作为测试样本, 以 2.3 所述 3 种健康特征为模型输入, 电池 SOH 为输出。将 IGWO-SVR 方法与 GWO-SVR、SVR 方法进行对比分析, 3 种估方法的参数设置如表 2 所示。在 SVR 方法中, 惩罚因子  $C=1$ , 核参数  $\sigma=0.01$ ; IGWO-SVR 方法和 GWO-SVR 方法参数设置一致, 分别为狼群数量  $SearchAgents\_no=16$ , 最大迭代数  $Max\_iteration=30$ , 变量数  $dim=2$ , 参数下界  $I_b=-100$ , 参数上界  $u_b=10$ 。

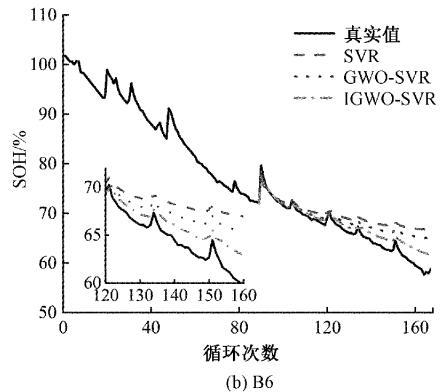
表 2 不同估方法参数设置

SOH 估计方法	参数设置
SVR	$C=1, \sigma=0.01$
GWO-SVR	$SearchAgents\_no=16, Max\_iteration=30, dim=2, I_b=-100, u_b=10$
IGWO-SVR	$SearchAgents\_no=16, Max\_iteration=30, dim=2, I_b=-100, u_b=10$

3 种方法的锂电池 SOH 估计结果如图 4 所示, 测试集中 SOH 真实值与估计值之间的误差绝对值如图 5 所示。

从图 4 中可以看出, IGWO-SVR 模型估计电池 SOH 的估计结果曲线最接近真实值, 估计误差最小。单一的 SVR 估计模型对不同电池的 SOH 估计能力差, 估计值与真实的 SOH 值相差较大。GWO-SVR 模型相比于 SVR 模型, 估计精度有部分提高, 但结果仍不理想, 不能准确地估计异常数据的波动。由 SOH 估计结果图可知, 当 B5 电池的 SOH 估计结果在循环次数为 130~135 时, 数据有较大的波动, 此时 SVR 和 GWO-SVR 模型的估计结果较差, 而 IGWO-SVR 模型可以较好地跟踪 SOH 的变化趋势。

由误差图可知, SVR 模型的估计误差在后期逐渐增大, 而 GWO-SVR 模型的估计误差虽有所降低, 但其估计精度低于 IGWO-SVR 模型且结果不够稳定。本文提出的 IGWO-SVR 模型具有较好的拟合能力, 实现了 SOH 的精确估计, 最大估计误差不超过 2%。



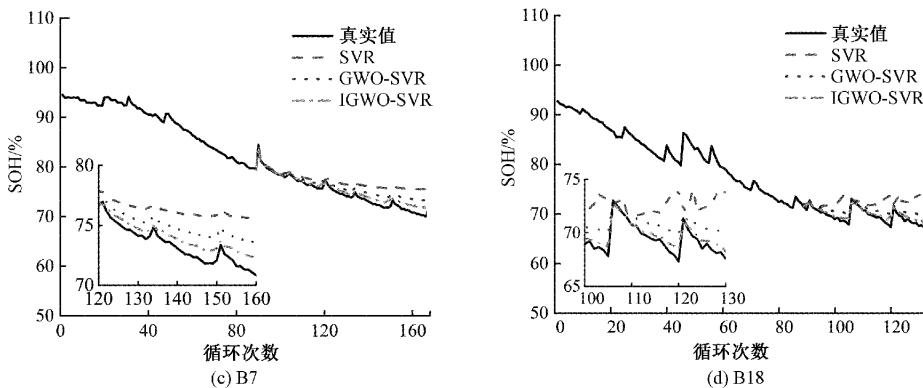


图 4 SOH 估计结果

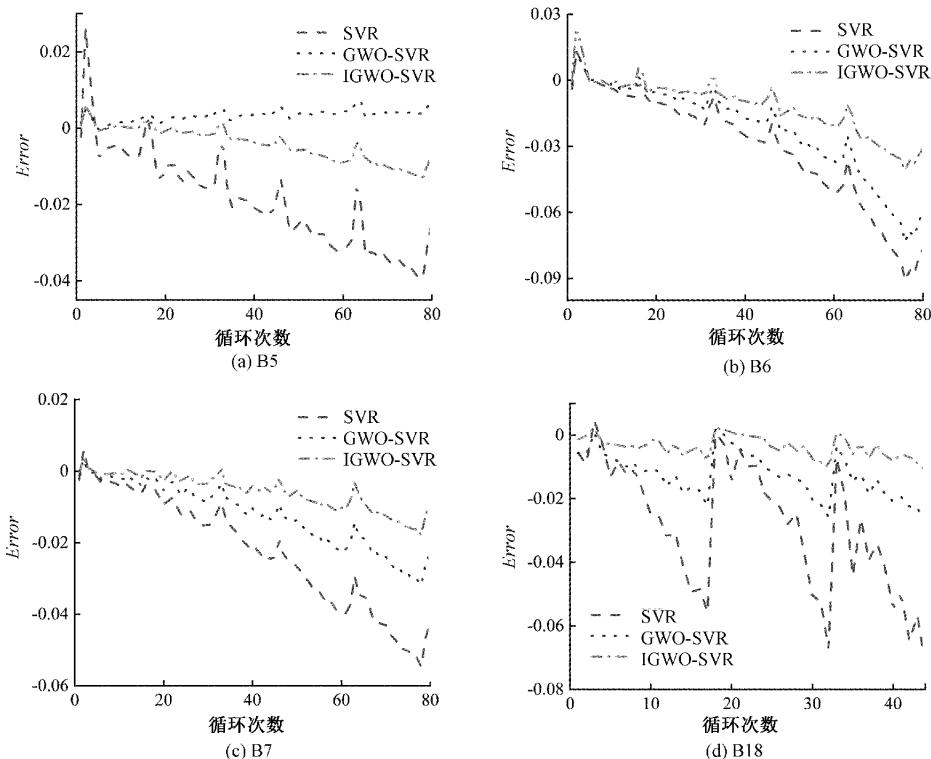


图 5 SOH 估计误差

根据评估标准,统计得到 3 种方法的 SOH 估计结果,如表 3 所示。

表 3 SOH 估计结果

电池编号	SVR		GWO-SVR		IGWO-SVR	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
B0005	2.469 5	0.022 6	1.333 6	0.013 2	0.573 0	0.006 0
B0006	3.911 6	0.040 1	2.863 9	0.030 6	1.662 1	0.017 3
B0007	2.678 9	0.275 7	1.463 2	0.015 3	0.688 5	0.007 5
B0018	3.937 6	0.035 0	1.734 3	0.014 4	0.556 8	0.004 9

由表 3 可得,采用 IGWO-SVR 方法得到的 SOH 估计结果的 MAPE 和 RMSE 平均值分别为 0.870 1%、0.008 9%。与 GWO-SVR 方法相比,IGWO-SVR 的 MAPE 和 RMSE 的平均值分别降低 2.379 3%,0.083 875。由此可得,相比于单一的 SVR 方

的平均值分别降低 0.978 6%、0.009 475。与 SVR 方法相比,IGWO-SVR 的 MAPE 和 RMSE 的平均值分别降低 2.379 3%,0.083 875。由此可得,相比于单一的 SVR 方

法,GWO 与 SVR 方法的结合能在一定程度上提高 SOH 的估计精度,而且通过对 GWO 算法的改进,MAPE 和 RESE 值都有不同程度的降低,能进一步提高估计精度,所以 IGWO-SVR 方法拟合程度更好,对电池 SOH 的估计有着更高的估计精度和鲁棒性。

#### 4 结 论

为提高锂电池 SOH 的估计精度,本文提出了一种基于 IGWO-SVR 的锂电池 SOH 估计方法。基于 NASA 电池数据集,对该模型进行训练及验证,并与 SVR 和 GWO-SVR 方法相比较。结果表明,IGWO-SVR 方法能有效提高 SOH 估计的精度和稳定性。本文得出的主要结论如下:

本文提取了 NASA 电池数据集中的电池容量,根据 SOH 的定义公式得到 SOH 的变化曲线,发现电池 SOH 符合时间序列和非线性特征,能较好地符合 SVR 所解决问题的特征。

SVR 方法的关键在于惩罚因子和核参数的选取,估计精度主要受这两个参数的影响,利用优化算法能较好地确定参数的取值。本文选用 IGWO 算法优化 SVR 的核参数,显著提高了 SOH 的估计精度。

本文提出的 IGWO-SVR 方法与其他方法相比,SOH 估计精度和稳定性有明显的提高,最大估计误差不超过 2%,呈现出较好的鲁棒性和准确性。

#### 参考文献

- [1] 夏克刚,钱祥忠,余懿衡,等.联合精确估算电池的健康状态[J].电子测量技术,2019,42(3):25-30.
- [2] 赵沁峰,蔡艳平,王新军.锂电池在不同放电区间下的剩余寿命预测[J].中国测试,2023,49(3):8.
- [3] 刘家豪,张宏伟,袁永军.基于 LSTM 和 EIS 的锂电池健康状态估计[J].传感器与微系统,2021,40(12):59-61,65.
- [4] 王义,刘欣,高德欣.基于 BiLSTM 神经网络的锂电池 SOH 估计与 RUL 预测[J].电子测量技术,2021,44(20):1-5.
- [5] MA G, ZHANG Y, CHENG C, et al. Remaining useful life prediction of lithium-ion batteries based on false nearest neighbors and a hybrid neural network, Appl[J]. Energy, 253(2019): 113626.
- [6] LI X, YUAN C, WANG Z. State of health estimation for Li-ion battery via partial incremental capacity analysis based on support vector regression [J]. Energy, 203(2020): 117852.
- [7] 贺宁,钱成,李若夏,等.压缩感知结合高斯过程回归的锂电池 SOH 估计[J].控制工程,2023,30(4):637-648.
- [8] 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.
- [9] 肖仁鑫,李沛森,李晓宇,等.基于蚁群神经网络算法的电池健康状态估计[J].电源技术,2017,41(6): 916-919.
- [10] LIN H T, LIANG T J, CHEN S M. Estimation of battery state of health using probabilistic neural network [J]. IEEE Transactions on Industrial Informatics, 2013, 9(2):679-685.
- [11] LI X, YUAN C, LI X, et al. Stage of health estimation for Li-Ion battery using incremental capacity analysis and Gaussian process regression[J]. Energy, 2020,190:116467.
- [12] ZHAO Q, QIN X, ZHAO H, et al. A novel prediction method based on the support vector regression for the remaining useful life of lithium-ion batteries[J]. Microelectronics Reliability, 2018, 85: 99-108.
- [13] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69:46-61.
- [14] 黎素涵,叶春明.重选精英个体的非线性收敛灰狼优化算法[J].计算机工程与应用,2021,57(1):62-68.
- [15] 王瀛洲,倪裕隆,郑宇清,等.基于 ALO-SVR 的锂离子电池剩余使用寿命预测[J].中国电机工程学报,2021, 41(4):1445-1457,1550.
- [16] 尹春杰,王亚男,李鹏飞,等.基于 LSTM 的储能蓄电池 SOC 与 SOH 联合在线估计[J].电源技术,2022, 46(5):541-544.
- [17] 李建林,李雅欣,陈光,等.退役动力电池健康状态特征提取及评估方法综述[J].中国电机工程学报,2022, 42(4):1332-1347.
- [18] 徐佳宁,倪裕隆,朱春波.基于改进支持向量回归的锂电池剩余寿命预测[J].电工技术学报,2021,36(17): 3693-3704.

#### 作者简介

- 梁杨,硕士研究生,主要研究方向为电池管理系统。  
E-mail: 1792881366@qq.com
- 周永军(通信作者),硕士研究生导师,硕士,副教授,主要研究方向为电池管理,汽车自动驾驶技术。  
E-mail: zyj424@126.com
- 蒋淑霞,硕士研究生导师,博士,副教授,主要研究方向为交通设备信息工程、汽车工程。  
E-mail: jiangshuxia\_2004@163.com
- 袁晓文,高级工程师。  
E-mail: yuanxiaowen3376@sina.com
- 张淞,硕士研究生,主要研究方向为电池管理系统。  
E-mail: 597804232@qq.com