



## 基于改进GWOSVR算法的锂电池剩余寿命预测

金辉 胡寅道 葛红娟 郝志鹏 曾郑志远 唐泽鹏

### Remaining useful life prediction for lithium-ion batteries based on an improved GWO-SVR algorithm

JIN Hui, HU Yinxiao, GE Hongjuan, HAO Zhipeng, ZENG Zhengzhiyuan, TANG Zepeng

引用本文:

金辉, 胡寅道, 葛红娟, 郝志鹏, 曾郑志远, 唐泽鹏. 基于改进GWO - SVR算法的锂电池剩余寿命预测[J]. *工程科学学报*, 2024, 46(3): 514-524. doi: 10.13374/j.issn2095-9389.2023.05.31.002

JIN Hui, HU Yinxiao, GE Hongjuan, HAO Zhipeng, ZENG Zhengzhiyuan, TANG Zepeng. Remaining useful life prediction for lithium-ion batteries based on an improved GWO - SVR algorithm[J]. *Chinese Journal of Engineering*, 2024, 46(3): 514-524. doi: 10.13374/j.issn2095-9389.2023.05.31.002

在线阅读 View online: <https://doi.org/10.13374/j.issn2095-9389.2023.05.31.002>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [基于集成神经网络的剩余寿命预测](#)

Remaining useful life prediction based on an integrated neural network

*工程科学学报*. 2020, 42(10): 1372 <https://doi.org/10.13374/j.issn2095-9389.2019.10.10.005>

#### [基于CEEMDANLSTM组合的锂离子电池寿命预测方法](#)

Combined prediction method of lithium-ion battery life based on CEEMDANLSTM

*工程科学学报*. 2021, 43(7): 985 <https://doi.org/10.13374/j.issn2095-9389.2020.06.30.007>

#### [等效循环电池组剩余使用寿命预测](#)

Investigation of RUL prediction of lithium-ion battery equivalent cycle battery pack

*工程科学学报*. 2020, 42(6): 796 <https://doi.org/10.13374/j.issn2095-9389.2019.07.03.003>

#### [基于融合模型的锂离子电池荷电状态在线估计](#)

Online estimation of the state of charge of a lithium-ion battery based on the fusion model

*工程科学学报*. 2020, 42(9): 1200 <https://doi.org/10.13374/j.issn2095-9389.2019.09.20.001>

#### [基于支持向量回归与极限学习机的高炉铁水温度预测](#)

Prediction of blast furnace hot metal temperature based on support vector regression and extreme learning machine

*工程科学学报*. 2021, 43(4): 569 <https://doi.org/10.13374/j.issn2095-9389.2020.05.28.001>

#### [锂离子电池安全性研究进展](#)

Research progress on safety of lithium-ion batteries

*工程科学学报*. 2018, 40(8): 901 <https://doi.org/10.13374/j.issn2095-9389.2018.08.002>

# 基于改进 GWO–SVR 算法的锂电池剩余寿命预测

金 辉<sup>1)</sup>, 胡寅道<sup>1)</sup>, 葛红娟<sup>1)✉</sup>, 郝志鹏<sup>2)</sup>, 曾郑志远<sup>1)</sup>, 唐泽鹏<sup>1)</sup>

1) 南京航空航天大学民航学院, 南京 211106 2) 中国民航科学技术研究院, 北京 100028

✉通信作者, E-mail: [allenge@nuaa.edu.cn](mailto:allenge@nuaa.edu.cn)

**摘 要** 锂离子电池性能优越, 已在 B787 等机型上得到应用. 锂离子电池性能随着使用次数增加而衰退, 准确预测锂电池剩余使用寿命从而及时维护/更换, 对航班安全飞行具有重要意义. 面向锂离子电池剩余寿命预测问题, 本文采用容量增量分析方法提取特征, 基于灰色关联分析计算特征与电池容量的关联程度并筛选特征, 提出一种基于改进灰狼优化算法 (Improved grey wolf optimization, IGWO) 和支持向量回归 (Support vector regression, SVR) 的锂离子电池剩余寿命预测方法. 作为近年研究热点的灰狼优化 (Grey wolf optimization, GWO) 算法寻优性能出色, 但是在应用中容易陷入局部最优. 针对此问题, IGWO 对 GWO 算法中的位置更新方程进行优化, 对狼群中的个体添加了记忆与飞行功能, 增强了算法全局搜索和收敛能力; 同时基于 Skew Tent 映射产生混沌序列, 优化狼群初始位置分布. 基于标准测试函数对比 GWO 和 IGWO 算法的寻优能力, 结果表明 IGWO 算法的收敛速度和寻优效果更好, 能够避开 GWO 陷入的局部最优, 在部分测试函数上将寻优精度提升了几十个数量级; 基于 NASA 锂离子电池数据集开展 IGWO–SVR、GWO–SVR 和 SVR 的剩余寿命预测能力对比实验, 结果证明 IGWO–SVR 能够有效提高预测精度, 与 GWO–SVR 相比预测均方根误差值降低了 10% 以上.

**关键词** 锂离子电池; 剩余寿命预测; 容量增量分析; 改进灰狼优化算法; 支持向量回归

**分类号** TG142.71

## Remaining useful life prediction for lithium-ion batteries based on an improved GWO–SVR algorithm

JIN Hui<sup>1)</sup>, HU Yinxiao<sup>1)</sup>, GE Hongjuan<sup>1)✉</sup>, HAO Zhipeng<sup>2)</sup>, ZENG Zhengzhiyuan<sup>1)</sup>, TANG Zepeng<sup>1)</sup>

1) College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China

2) China Academy of Civil Aviation Science and Technology, Beijing 100028, China

✉Corresponding author, E-mail: [allenge@nuaa.edu.cn](mailto:allenge@nuaa.edu.cn)

**ABSTRACT** Lithium-ion batteries have been applied in civil aircraft such as the B787 with excellent performance. As the service time of lithium-ion batteries increases, their performance continues to decline. Therefore, accurately predicting the remaining useful life of lithium-ion batteries is helpful for timely maintenance or replacement, which is important for flight safety. This study extracts features from charge and discharge data of lithium-ion batteries with incremental capacity analysis to predict the remaining useful life of lithium-ion batteries. To this end, this study calculates the degree of correlation between the features and battery capacity based on grey correlation analysis, and then accordingly filters the features. Finally, a prediction method for the remaining useful life of lithium-ion batteries is proposed based on improved grey wolf optimization (IGWO) and support vector regression (SVR). The IGWO algorithm is proposed to solve the issue wherein grey wolf optimization (GWO) is prone to stagnation at local optima. As a research hotspot in the field of optimization algorithms in recent years, GWO has excellent optimization performance. However, it faces the problem of falling into local optimization and premature convergence in practical applications. To solve this problem, this study proposes IGWO to

收稿日期: 2023–05–31

基金项目: 国家自然科学基金民航联合基金重点资助项目 (U2233205, U2133203)

optimize and rewrite the position update equation and add memory and flight functions to each individual in the wolf pack so as to enhance the global search ability of the algorithm and improve its convergence speed. Furthermore, IGWO uses skew tent mapping to generate chaotic sequences to optimize the initial distribution of the grey wolf pack in the optimization space. Thus, it achieves a more uniform initial distribution effect than the traditional random generation method. This paper conducts an optimization comparison experiment based on commonly used benchmark functions to compare the optimization ability of GWO before and after improvement. The results show that the IGWO algorithm effectively avoids the stagnation at a local optimal value that the GWO algorithm will fall into, with faster convergence speed and better optimization than GWO for almost all functions. In several of these test functions, the optimization accuracy of IGWO is dozens of times higher than that of GWO. The remaining useful life prediction abilities of IGWO-SVR, GWO-SVR, and SVR are compared based on the NASA lithium-ion battery dataset. The results show that the model trained with IGWO-SVR achieves higher prediction accuracy on the data among all four batteries, and the root mean square error of the prediction results is reduced by more than 10% compared with GWO-SVR.

**KEY WORDS** lithium-ion battery; remaining useful life prediction; incremental capacity curve analysis; improved grey wolf optimization; support vector regression

锂离子电池具有能量密度高、使用寿命长、体积小重量轻等优势<sup>[1-2]</sup>, 已经成为了机载蓄电池的发展趋势<sup>[3]</sup>. 随着充放电次数增加, 锂电池性能退化, 电池容量降低, 剩余使用寿命(Remaining useful life, RUL)减少<sup>[4-5]</sup>. 以 B787 机载锂电池热失控为代表的系列事故暴露出机载锂电池的安全管理问题<sup>[6]</sup>. 容量是反映电池性能水平的一项重要指标<sup>[7]</sup>, 目前机务人员主要通过满容量充放电法检测电池容量从而判断其性能水平, 但该方法成本较高且会消耗电池寿命. 寻找可靠方法监测锂电池性能进行准确的 RUL 预测, 对机载锂电池的安全管理与航班安全运行至关重要.

国内外学者针对锂电池 RUL 预测开展了诸多研究, 所用方法主要分为基于模型和数据驱动两种<sup>[8]</sup>. 基于模型的 RUL 预测方法需要分析锂电池的内部结构、电化学特性和失效机理, 从而建立电池性能退化模型开展预测<sup>[9]</sup>. Khodadadi Sadabadi 等<sup>[10]</sup>基于锂电池的电化学特性提出一种增强单粒子模型, 对车载锂电池进行 RUL 预测. El Mejdoub 等<sup>[11]</sup>以锂电池老化条件为输入建立性能退化模型, 通过评估容量和电阻的变化趋势实现 RUF 预测. 此类方法均需要分析电池退化机理, 预测精度由性能退化模型的准确程度决定<sup>[12]</sup>. 机载蓄电池工作条件恶劣、环境因素复杂, 难以建立准确的退化模型.

数据驱动方法则基于电池充放电数据实现 RUF 预测, 无需分析电池内部机理, 泛化性和精度好且成本较低<sup>[13]</sup>. 魏孟等<sup>[14]</sup>从锂电池放电数据中提取间接健康因子, 基于非线性自回归动态神经网络建立了锂电池 RUL 预测模型. 徐佳宁等<sup>[15]</sup>基于支持向量回归(Support vector regression, SVR)算法建立锂电池 RUL 预测模型并提出一种改进蚁狮优化算

法调整 SVR 参数, 提高了锂离子电池 RUL 预测的准确性. Zhang 等<sup>[16]</sup>利用相关分析法在增量容量曲线中提取特征, 利用神经网络建立 RUL 预测模型.

采用数据驱动的方法进行锂电池 RUF 预测, 通常需要借助寻优算法对模型训练算法的参数进行寻优. 近年来, 具有收敛性能强、参数少等优点的灰狼优化算法(Grey wolf optimization, GWO), 得到了研究者的关注和广泛应用<sup>[17]</sup>. 王岩韬等<sup>[18]</sup>面向雷暴天气下区域内多航班集体备降问题, 基于 GWO 提出一种多航班备降动态优化方案; 王桥等<sup>[19]</sup>采用 GWO 算法对极限学习机的超参数进行优化, 建立了锂电池荷电状态评估模型.

实际应用中, GWO 算法存在容易陷入局部最优的问题<sup>[20]</sup>. 针对此问题, 本文对 GWO 算法中的核心表达式——位置更新方程进行改进, 为狼群引入飞行和记忆能力, 并采用 Skew Tent 映射对狼群初始位置分布进行优化, 提出一种改进灰狼优化算法(Improved grey wolf optimization, IGWO). 采用 19 种标准测试函数对比了 IGWO 和 GWO 算法的寻优能力, 证明 IGWO 具有更好的寻优精度和收敛能力. 进一步, 论文基于容量增量分析和灰色关联分析等算法从锂电池的电压、电流数据中提取并筛选特征, 提出基于 IGWO-SVR 的锂电池 RUL 预测方法, 并利用 NASA 锂电池数据集开展验证实验. 结果表明, 本文所提方法能够实现更加准确的锂离子电池 RUL 预测.

## 1 基于 IGWO-SVR 的 RUF 预测模型构建方法

### 1.1 支持向量回归与灰狼优化算法

SVR 基于训练集  $T = \{(x_1, y_1), \dots, (x_N, y_N)\}$  训练

模型, 其中  $x_i$  和  $y_i$  分别对应第  $i$  个样本的输入向量和输出值. 训练过程中, SVR 利用非线性映射  $\phi(x)$  将训练集从低维空间映射到高维空间, 该过程表达式为:  $f(x) = \omega\phi(x) + b$ ,  $\omega$  和  $b$  分别代表权重与截距. SVR 根据结构风险最小化原则求解  $f(x)$  的过程可以表示为求解约束最优化问题<sup>[21]</sup>:

$$\begin{aligned} \min_{\omega, b} & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N (\xi_i^A + \xi_i^V) \\ \text{s.t.} & y_i - (\omega \cdot x_i + b) \leq \varepsilon + \xi_i^A, \\ & \xi_i^A \geq 0, \quad i = 1, 2, \dots, N \\ & y_i - (\omega \cdot x_i + b) \geq -(\varepsilon + \xi_i^V), \\ & \xi_i^V \geq 0, \quad i = 1, 2, \dots, N \end{aligned} \quad (1)$$

其中:  $C$  为惩罚参数, 负责调节样本回归模型的复杂性与样本拟合精度;  $\xi_i^A$  和  $\xi_i^V$  分别代表上下界的松弛变量;  $\varepsilon$  代表不敏感损失因子.

引入拉格朗日乘法算子和对偶原理, 基于序列最小优化算法求解得到最优拉格朗日乘数参数  $\alpha^A$  和  $\alpha^V$ . 引入核函数, 得到非线性映射 SVR 表达式为:

$$f(x) = \omega\phi(x) + b = \sum_i^N (\alpha_i^{A*} - \alpha_i^{V*}) K(x_i, x) \quad (2)$$

其中,  $K(x_i, x) = \phi(x_i)\phi(x)$  代表核函数.

本文选取普适性好, 应用广泛的径向基核函数 (Radial basis function, RBF) 作为核函数, 其表达式为:  $K_{\text{RBF}}(x_i, x) = \exp(-\gamma \|x_i - x\|^2)$ , 其中  $\gamma = 1/(2\sigma^2)$  为核参数,  $\sigma$  为带宽参数.

在 SVR 中, 惩罚参数  $C$ 、不敏感损失因子  $\varepsilon$  和核参数  $\gamma$  是影响其预测性能的主要参数, 为了提高预测精度, 本文采用灰狼优化算法对这三个参数进行寻优.

自然界的狼群具有严格等级制度, 通常分为  $\alpha$ 、 $\beta$ 、 $\delta$  和  $w$  四个等级, 对应在 GWO 算法中的最优解、次优解、季优解以及所有候选解. 假设狼群规模为  $N_w$ ,  $X_i = (X_i^1, X_i^2, \dots, X_i^S)$  代表第  $i$  只狼所处位置,  $S$  代表寻优空间维数 (即寻优参数数量), GWO 寻优过程中狼群各行为的表达式为<sup>[22]</sup>:

1) 包围猎物: 设第  $i$  只狼与猎物之间距离为  $D_i = |P_r \cdot X_p - X_i|$ , 包围猎物过程的数学表达如下:

$$X'_i = X_p - A \cdot D_i \quad (3)$$

其中,  $X'_i$  代表第  $i$  只灰狼移动后所处的新位置,  $X_p$  代表猎物位置;  $A$  和  $P_r$  均为位置变量,  $A = 2a \cdot r_1 - a$ ,  $P_r = 2r_2$ .  $r_1$  和  $r_2$  为模取值在  $[0, 1]$  之间的随机

变量,  $a = 2 - 2 \cdot t/t_{\max}$  代表收敛因子,  $t$  和  $t_{\max}$  分别代表当前迭代次数与最大迭代次数.

2) 搜寻猎物: 灰狼个体  $i$  搜寻猎物的过程主要依靠位置更新方程实现, 表达式如下:

$$\begin{cases} X_{i1} = X_\alpha - A \cdot D_{i\alpha} \\ X_{i2} = X_\beta - A \cdot D_{i\beta} \\ X_{i3} = X_\delta - A \cdot D_{i\delta} \end{cases} \quad (4)$$

$$X'_i = (X_{i1} + X_{i2} + X_{i3})/3 \quad (5)$$

式中:  $X_\alpha$ 、 $X_\beta$  和  $X_\delta$  分别代表  $\alpha$ 、 $\beta$  和  $\delta$  狼所处的位置;  $D_{i\alpha}$ 、 $D_{i\beta}$  和  $D_{i\delta}$  分别代表第  $i$  个灰狼与  $\alpha$ 、 $\beta$  和  $\delta$  狼之间的距离;  $X_{i1}$ 、 $X_{i2}$  和  $X_{i3}$  分别代表第  $i$  个灰狼向  $\alpha$ 、 $\beta$  和  $\delta$  狼方向移动的目标位置.

3) 攻击猎物:  $A$  的取值在  $[-a, a]$  区间内, 在迭代过程中,  $a$  的直线性递减, 使得  $A$  的变化范围随之减小, 从而模拟逼近猎物.

## 1.2 增加记忆功能的改进灰狼优化算法

GWO 算法借助组件  $P_r$  的随机性提供全局搜索, 一定程度避免陷入局部最优. 但是在实际应用中, 尤其是求解多峰值问题时, GWO 仍然常会面临陷入局部最优, 出现早熟收敛的问题. 针对该问题, 本文对 GWO 算法的种群初始化方法和位置更新方程进行优化改进, 提出改进灰狼优化算法 IGWO.

在 GWO 算法中根据寻优变量的上下界设置来随机初始化灰狼个体的位置, 这种方法存在位置初始分布不均匀的风险, 制约收敛速度. 混沌具有随机性和遍历性和初值敏感性, 能使算法有更快的收敛速度. 为了使初始种群个体尽可能地利用解空间的信息, 本文采用 Skew Tent 映射<sup>[23]</sup> 产生混沌序列用来对 IGWO 进行种群初始化. 基于 Tent 映射生成混沌序列的过程的数学表达式如下:

$$\begin{cases} T'_i = T_i/\varphi, & 0 < T_i \leq \varphi \\ T'_i = (1 - T_i)/(1 - \varphi), & \varphi < T_i < 1 \end{cases} \quad (6)$$

式中,  $\varphi$  为映射参数, 取值在  $(0, 1)$  之间,  $T_i$  和  $T'_i$  分别代表种群中第  $i$  个样本在映射前后的位置.

在范围为  $(0, 100)$  的一维空间中, 对个体数量为 10 的种群, 采用随机生成方式和 Tent 映射分别进行了十次种群初始化, 效果如图 1 所示. 图中纵横坐标分别代表迭代次数和个体所处位置. 可以看出, 采用 Tent 映射进行种群初始化, 在不同迭代次数下的个体分布情况都更加均匀.

随后, 通过引入 Levy 飞行<sup>[24]</sup>, 使得距离  $\alpha$ 、 $\beta$ 、 $\delta$  狼较远 (即  $|A| \geq 0.5$ ) 的个体增强搜索范围, 得到新的位置更新方程:



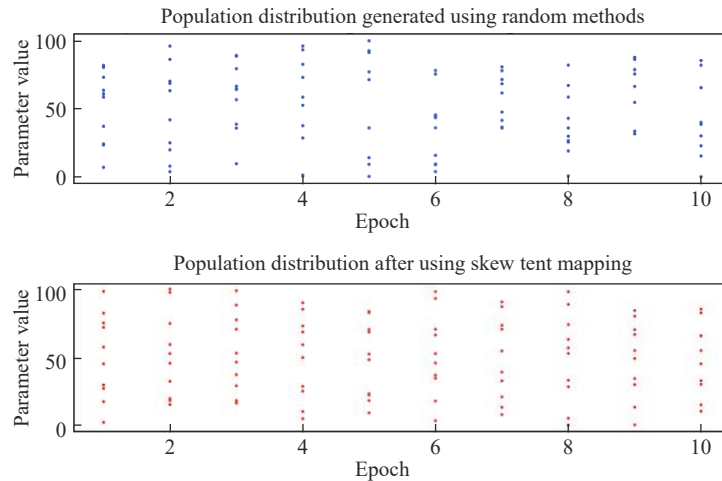


图1 随机方式与 Tent 映射产生的种群分布效果对比

Fig.1 Comparison of population distribution generated by the random method and tent mapping

$$X'_i = \begin{cases} \frac{X_{i1} + X_{i2} + X_{i3}}{3} + \mu \text{Levy}(s), & |A| \geq 0.5 \\ \frac{X_{i1} + X_{i2} + X_{i3}}{3}, & |A| \leq 0.5 \end{cases} \quad (7)$$

式中,  $s$  为步长, 可表示为  $s = u/|v|^{1/\lambda}$ , 其中  $u$  和  $v$  均为正态分布随机数,  $\lambda$  为飞行参数。

$\mu$  为步长控制因子, 表示步长的控制量, 通常等于 1, 但是  $\mu$  固定取值下的搜索能力较差, 且无法在搜索过程中提供准确性。

因此, 本文提出一种新型随机动态控制因子  $\mu$ , 使算法随着迭代而逐渐收敛, 表达式如下:

$$\mu = \left(1 - \frac{t-1}{t_{\max}}\right) \times \exp(R-0.5) \quad (8)$$

其中,  $R \in [0, 1]$ , 是满足正态分布的随机数。

与线性递减因子相比, 随机动态控制因子随着迭代次数增加逐渐衰减为 0 的同时, 额外引入了取值随机性:  $\mu$  取值在下降过程中随机波动, 迭代次数越小, 波动幅度越大, 从而增强了算法在迭代前中期的搜索能力。

在此基础上, 为进一步增强算法的探索能力和加快收敛速度, IGWO 借鉴粒子群寻优算法中对粒子自身运动历史最优解进行记忆保存的思想, 对灰狼增加记忆功能: 在迭代过程中保存每个灰狼的历史最优位置记录, 使狼群在靠近记忆中的最佳位置时, 在听从  $\alpha$  狼指挥的同时也会参考自身记忆进行移动。

最终提出一种改进位置更新方程为:

$$X'_i = \begin{cases} \frac{X_{i1} + X_{i2} + X_{i3}}{3}, & |A| \leq 0.5 \\ \frac{X_{i1} + X_{ih} - A \cdot D_{ih}}{2}, & |A| \geq 0.5, |D_{ih}| < 1 \\ \frac{X_{i1} + X_{i2} + X_{i3}}{3} + \mu \cdot \text{Levy}(s), & |A| \geq 0.5 \end{cases} \quad (9)$$

其中,  $X_{ih}$  代表灰狼  $i$  所经历的历史最佳位置,  $D_{ih}$  代表灰狼  $i$  当前位置和历史最佳位置的距离。

这种改动引入了个体自身最优位置记忆, 理论上可以加强算法的开发能力以及加快收敛速度。

### 1.3 基于 IGWO-SVR 的锂电池 RUF 预测

提出利用 IGWO 算法对 SVR 的惩罚参数  $C$ 、不敏感损失因子  $\varepsilon$  和核参数  $\gamma$  进行寻优, 建立锂电池 RUF 预测模型的流程, 如图 2 所示。

基于 IGWO-SVR 开展锂电池 RUL 预测的具体过程如下:

1) 数据处理: 对锂电池充电数据集进行预处理, 从锂电池充电电压、电流等可监测外特性参数中提取特征, 并根据相关性分析结果筛选特征集合, 最后根据设定的预测起点划分训练集、验证集和测试集。

2) 参数设置与初始位置生成: 设置狼群规模为 30, 最大迭代次数为 500, 惩罚参数  $C$ 、不敏感损失因子  $\varepsilon$  和核参数  $\gamma$  的寻优边界范围依次为 (0.1, 10000)、(0.001, 1) 和 (0.0001, 1); 基于 Skew Tent 混沌序列生成灰狼个体初始位置。

3) 建立适应度函数: 根据当前迭代次数下的寻优结果, 基于训练集建立 RUL 预测模型. 将验证集数据输入模型, 计算实际容量值和预测值之间的均方根误差 (Root mean square error, RMSE) 作为适应度函数。

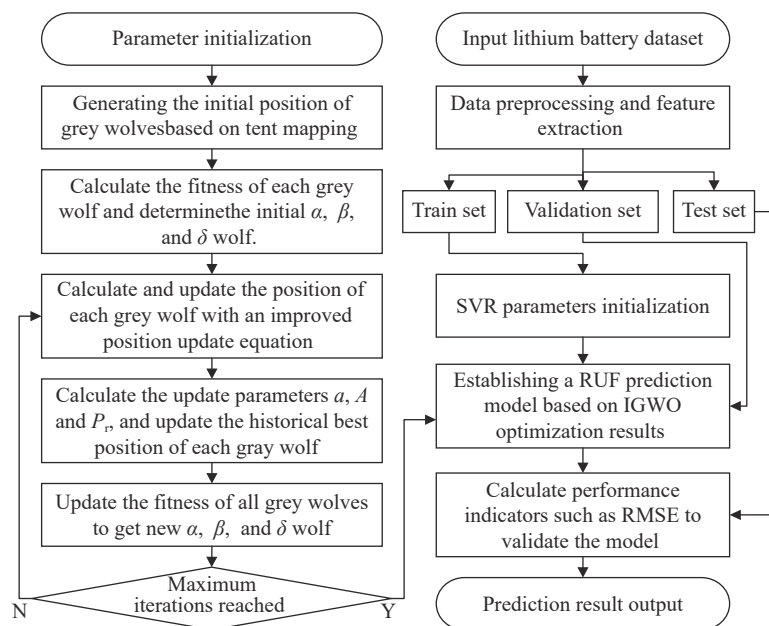


图 2 基于 IGWO-SVR 的锂电池 RUL 预测流程

Fig.2 RUL prediction and performance assessment process of lithium-ion batteries based on IGWO-SVR

4) 参数寻优: 以验证集 RMSE 最小为寻优目标, “狼群”根据式 (9) 改进位置更新方程在迭代中逐渐逼近参数  $C$ 、 $\varepsilon$  和  $\gamma$  的最优组合. 迭代至最大迭代次数后, 根据寻优到的最佳参数组合, 建立最终的锂电池 RUL 预测模型.

5) 开展 RUL 预测: 将测试集代入训练完成的模型进行 RUL 预测, 计算 RMSE 等指标检验模型预测效果.

## 2 改进 GWO 算法的寻优能力分析

本文中的所有实验均在 Intel Core i5-12400F, 2.5 GHz CPU, 16G 内存的 windows 11 系统下的 PC 上利用 python 3.10 进行程序的编写、调试与运行.

采用 IGWO 算法对 19 个经典标准测试函数进行求解, 并与标准 GWO 算法的结果进行比较. 其中, F1 ~ F7 为单峰测试函数, F8 ~ F19 为多峰测试函数.

在对比实验中, GWO 和 IGWO 算法的种群规模均设置为 30, 最大迭代次数均设置为 500. 采用 GWO 和 IGWO 对各个测试函数均进行 10 次寻优, 分别统计最优精度值 (Best)、平均精度值 (Mean)、最差精度值 (Worst) 和精度标准差值 (St.dev), 得到表 1. 其中, Best、Worst 反映了解的质量; Mean 代表在给定的迭代次数下算法最终所能达到精度的平均值, 反映了算法的收敛速度; St.dev 反映了算法的稳定性和鲁棒性.

从表中结果可见, 本文提出的 IGWO 算法在

大部分标准测试函数上性能优于传统 GWO 算法. 除了在 F9 到 F11 和 F19 上 IGWO 与 GWO 算法寻优结果相同外, 其他函数上, IGWO 算法均取得了更好的平均精度值. 在 F1 到 F4 标准测试函数上, IGWO 算法的优势最明显, 平均寻优精度提升了数十乃至上百个数量级. 对于函数 F1 和 F3, 使用 IGWO 算法能够寻找到 GWO 算法未能找到的最优解 0.

图 3 给出了在其中一次试验中, IGWO 算法与 GWO 算法在 F4 ~ F11 测试函数上的收敛曲线. 可以看出, 在测试函数 F4 ~ F7 上, IGWO 算法能够更有效的避免局部最优, 取得更好的收敛精度. 在 F8 ~ F11 上, 虽然 IGWO 和 GWO 最后取得的寻优精度相同, 但是 IGWO 的收敛速度更具优势.

## 3 基于 IGWO-SVR 的锂电池 RUL 预测方法验证

### 3.1 基于容量增量分析的锂离子电池特征提取方法

本文使用美国航空航天局 NASA 公开的锂离子电池实验数据集进行实验. NASA 实验过程中, 所有电池均采用恒流-恒压模式 (Constant current-constant voltage, CC-CV) 进行充电: 电池充电阶段以 1.5 A 恒流 CC 模式充电至电池电压达到 4.2 V, 然后以恒压 CV 模式继续充电至充电电流降到 20 mA. 对于本文采用的 B0005、B0006、B0007 和 B0018 电池, 放电阶段以 2 A 电流恒流放电直到电池电压分别下降到 2.7、2.5、2.2 和 2.5 V.

通过观察不同循环次数下采集的充放电电

表 1 标准测试函数寻优结果

Table 1 Results of benchmark problems

| Number of functions | Dimension | GWO                    |                         |                        |                        | IGWO                    |                         |                         |                         |
|---------------------|-----------|------------------------|-------------------------|------------------------|------------------------|-------------------------|-------------------------|-------------------------|-------------------------|
|                     |           | Best                   | Worst                   | Mean                   | St.dev                 | Best                    | Worst                   | Mean                    | St.dev                  |
| F1                  | 30        | $1.89 \times 10^{-88}$ | $8.184 \times 10^{-82}$ | $6.11 \times 10^{-80}$ | $1.83 \times 10^{-80}$ | 0                       | $7.75 \times 10^{-238}$ | $7.75 \times 10^{-237}$ | 0                       |
| F2                  | 30        | $8.45 \times 10^{-57}$ | $9.64 \times 10^{-52}$  | $7.52 \times 10^{-51}$ | $2.21 \times 10^{-51}$ | $3.83 \times 10^{-190}$ | $1.03 \times 10^{-113}$ | $3.08 \times 10^{-112}$ | $9.24 \times 10^{-113}$ |
| F3                  | 30        | $2.21 \times 10^{-24}$ | $5.21 \times 10^{-12}$  | $4.94 \times 10^{-11}$ | $1.48 \times 10^{-11}$ | 0                       | $3.19 \times 10^{-226}$ | $3.19 \times 10^{-225}$ | 0                       |
| F4                  | 30        | $1.33 \times 10^{-31}$ | $5.76 \times 10^{-30}$  | $3.44 \times 10^{-29}$ | $1.05 \times 10^{-29}$ | $6.06 \times 10^{-195}$ | $1.1 \times 10^{-131}$  | $1.19 \times 10^{-130}$ | $3.59 \times 10^{-131}$ |
| F5                  | 30        | $2.85 \times 10^1$     | $2.88 \times 10^1$      | $2.89 \times 10^1$     | $1.07 \times 10^{-1}$  | $4.09 \times 10^{-4}$   | $2.34 \times 10^{-2}$   | $7.94 \times 10^{-2}$   | $2.41 \times 10^{-2}$   |
| F6                  | 30        | 1.26                   | 2.24                    | 3.03                   | $5.25 \times 10^{-1}$  | $1.51 \times 10^{-10}$  | $1.19 \times 10^{-5}$   | $5.91 \times 10^{-5}$   | $1.72 \times 10^{-5}$   |
| F7                  | 30        | $3.89 \times 10^{-6}$  | $7.25 \times 10^{-5}$   | $2.38 \times 10^{-4}$  | $5.62 \times 10^{-5}$  | $1.31 \times 10^{-6}$   | $6.27 \times 10^{-5}$   | $2.29 \times 10^{-4}$   | $7.74 \times 10^{-5}$   |
| F8                  | 30        | $-1.26 \times 10^4$    | $-1.08 \times 10^4$     | $-9.02 \times 10^3$    | $1.77 \times 10^3$     | $-1.26 \times 10^4$     | $-1.26 \times 10^4$     | $-1.26 \times 10^4$     | $4.38 \times 10^{-1}$   |
| F9                  | 30        | 0                      | 0                       | 0                      | 0                      | 0                       | 0                       | 0                       | 0                       |
| F10                 | 30        | $4.44 \times 10^{-16}$ | $4.44 \times 10^{-16}$  | $4.44 \times 10^{-16}$ | 0                      | $4.44 \times 10^{-16}$  | $4.44 \times 10^{-16}$  | $4.44 \times 10^{-16}$  | 0                       |
| F11                 | 30        | 0                      | 0                       | 0                      | 0                      | 0                       | 0                       | 0                       | 0                       |
| F12                 | 30        | $7.34 \times 10^{-2}$  | $1.98 \times 10^{-1}$   | $4.17 \times 10^{-1}$  | $8.98 \times 10^{-2}$  | $8.08 \times 10^{-4}$   | $5.72 \times 10^{-3}$   | $6.49 \times 10^{-3}$   | $1.69 \times 10^{-3}$   |
| F13                 | 30        | $7.35 \times 10^{-1}$  | 1.19                    | 1.64                   | $2.89 \times 10^{-1}$  | $2.85 \times 10^{-9}$   | $2.61 \times 10^{-5}$   | $1.33 \times 10^{-4}$   | $4.54 \times 10^{-5}$   |
| F14                 | 2         | $9.98 \times 10^{-1}$  | 7.73                    | $1.27 \times 10^1$     | 3.82                   | $9.98 \times 10^{-1}$   | 1.00                    | 1.03                    | $9.82 \times 10^{-3}$   |
| F15                 | 4         | $3.41 \times 10^{-4}$  | $6.53 \times 10^{-3}$   | $2.22 \times 10^{-2}$  | $8.01 \times 10^{-3}$  | $3.45 \times 10^{-4}$   | $4.58 \times 10^{-4}$   | $6.89 \times 10^{-4}$   | $1.01 \times 10^{-4}$   |
| F16                 | 2         | -1.03                  | -1.02                   | $-9.58 \times 10^{-1}$ | $2.22 \times 10^{-2}$  | -1.03                   | -1.03                   | -1.02                   | $2.34 \times 10^{-3}$   |
| F17                 | 2         | $3.99 \times 10^{-1}$  | $4.53 \times 10^{-1}$   | $5.93 \times 10^{-1}$  | $6.42 \times 10^{-2}$  | $3.98 \times 10^{-1}$   | $4.42 \times 10^{-1}$   | $6.21 \times 10^{-1}$   | $6.23 \times 10^{-2}$   |
| F18                 | 2         | 3.01                   | 8.02                    | $3.16 \times 10^1$     | 9.90                   | 3.02                    | 7.06                    | $3.06 \times 10^1$      | 7.97                    |
| F19                 | 3         | $-3.00 \times 10^{-1}$ | $-3.00 \times 10^{-1}$  | $-3.00 \times 10^{-1}$ | 0                      | $-3.00 \times 10^{-1}$  | $-3.00 \times 10^{-1}$  | $-3.00 \times 10^{-1}$  | 0                       |

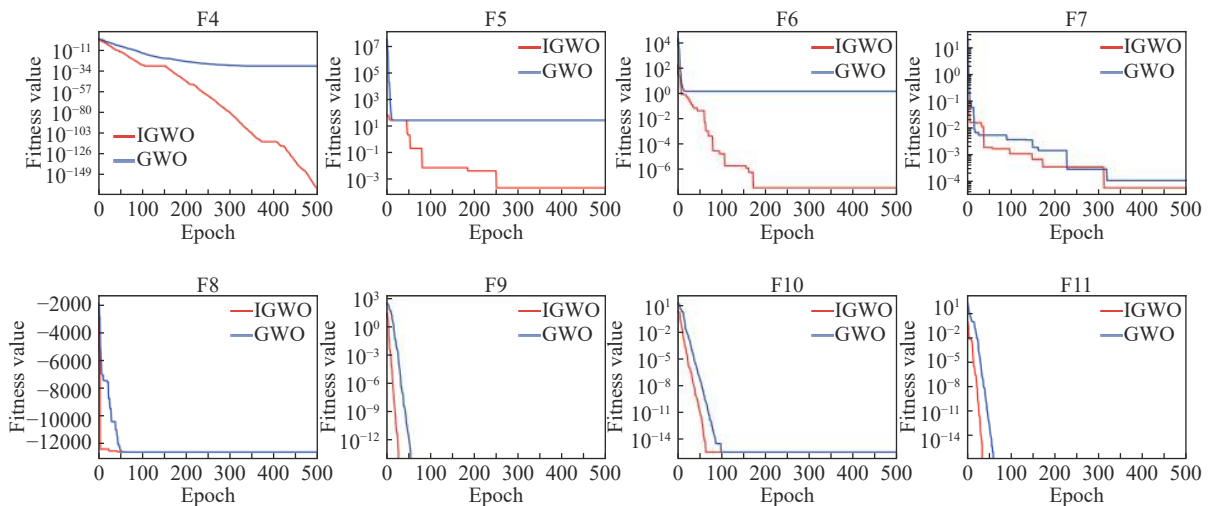


图 3 IGWO 与 GWO 在测试函数 F4 ~ F11 上的收敛曲线

Fig.3 Convergence curves of the proposed IGWO and GWO for F4-F11

压、电流及温度数据发现, 电池容量与充电次数, 总充电时长, CC 充电时长, CC 放电时长等特征密切相关. 除了这些可以直接观察到的特征外, 电池充电数据中还蕴含着反映电池内在特定化学反应过程的微分特征<sup>[25]</sup>. 容量增量分析(Incremental capacity, IC)是提取锂电池微分特征的常用方法.

本文将时间变化作为数据采样的判定指标, 从锂电池充电电压数据中获取容量增量数据绘制 IC 曲线. 采样时间间隔参考经验值设置为 10 s. 随后, 基于 Savitzky-Golay 滤波和卡尔曼滤波对不同循环次数下的 IC 曲线平滑降噪, 得到图 4.

观察对比 IC 曲线的变化可以看出: 随着电池

容量的下降, IC 曲线的起点逐渐右移; 电压 3.8 V 到 4.1 V 区间的 IC 曲线波峰面积随之下降; 电压 4.1 V 之后的 IC 曲线末端均值减少。

灰色关联分析算法能够根据不同因素间变化趋势的相似程度解算灰色关联度, 量化不同因素之间的关联程度<sup>[26]</sup>。本文采用灰色关联分析算法, 在不同电池的数据上分别计算上述特征与容量之间的关联程度, 结果如表 2 所示。

可以看出, CC 充电时长、充电次数、CC 放电时长和 IC 曲线波峰面积四项特征, 在不同电池的数据中与电池容量的灰色关联度均较高, 显著高于其他几项特征的灰色关联度。因此, 根据灰色关联分析结果, 本文筛选出 CC 充电时长等四项特征组成特征集, 开展锂电池剩余寿命预测试验。

### 3.2 锂电池 RUF 预测效果对比实验

使用 NASA 数据集, 分别基于 SVR、GWO-SVR 和 IGWO-SVR 训练建立预测模型, 对比算法效果。对于 SVR, 设置其惩罚参数  $C=10$ , 核参数  $\gamma=0.01$ , 不敏感损失因子  $\epsilon=0.1$ 。GWO 和 IGWO 设置同上节所述。在使用 GWO 和 IGWO 算法寻优过程中, 使用预测起点之前的数据组成训练集, 将预测起

点之后的数据用于测试。为避免过拟合, 将训练集中的前半部分用于训练, 使用全部的训练集数据进行验证, 以验证结果的均方根误差最小为目标进行参数寻优。

在 NASA 锂电池实验中, 大部分电池经历了 160 余次充放电循环, 且电池寿命终止均发生在中间值 80 次以后, 因此本文首先选择充放电循环次数达到 80 作为预测起点进行实验。为了对比验证在预测周期更长的场景下, 不同算法的预测效果, 将循环次数 60 作为预测起点进一步开展实验。

当预测起点设置为 80 时, 基于 SVR、GWO-SVR 和 IGWO-SVR 训练得到模型的 RUL 预测结果见图 5, 图中蓝色折线为电池容量的实际值, 黑色竖线代表预测起点的充放电循环次数(80 次), 灰色横线代表寿命终止阈值的电池容量(1.42 A·h); 绿色、橘色和红色折线依次代表使用 SVR、GWO-SVR 和 IGWO-SVR 的预测结果, 同色系竖线则分别标注出了电池实际寿命终止时循环次数和不同算法预测的循环次数。

b 从图中可见, 三种算法均能够不同程度的预测电池的容量衰退, 且有效识别出容量回升, 说明

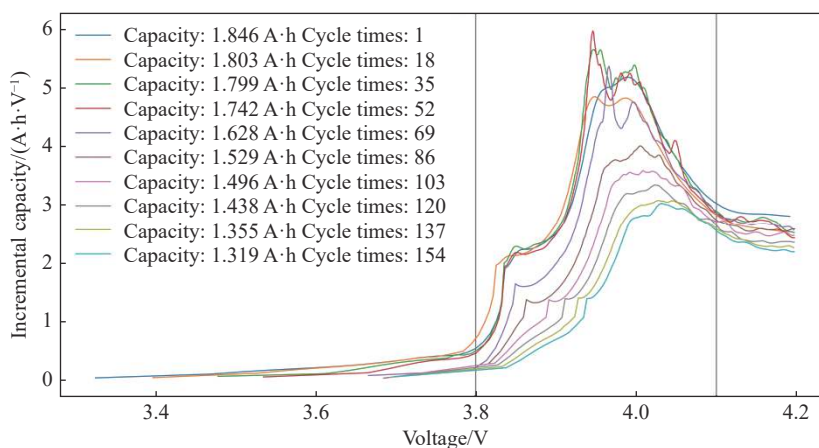


图 4 滤波后不同充电次数下的 IC 曲线

Fig.4 IC curves under different cycle times after filtering

表 2 各项特征与电池容量的灰色关联度

Table 2 Grey correlation degree between various features and battery capacity

| Battery number | Grey correlation degree |                   |               |                   |                              |                       |                                    |
|----------------|-------------------------|-------------------|---------------|-------------------|------------------------------|-----------------------|------------------------------------|
|                | CC charge time          | Total charge time | Charge cycles | CC discharge time | Starting voltage of IC curve | Peak area of IC curve | Average IC at the end of the curve |
| B0005          | 0.956                   | 0.808             | 0.878         | 0.993             | 0.666                        | 0.911                 | 0.839                              |
| B0006          | 0.923                   | 0.765             | 0.877         | 0.988             | 0.681                        | 0.884                 | 0.761                              |
| B0007          | 0.975                   | 0.845             | 0.906         | 0.981             | 0.714                        | 0.832                 | 0.563                              |
| B0018          | 0.849                   | 0.668             | 0.827         | 0.983             | 0.692                        | 0.702                 | 0.605                              |



本文选取的特征组合有效. 在引入 GWO 和 IGWO 算法进行参数寻优后, RUL 预测效果显著提升. 与 GWO-SVR 相比, 使用 IGWO-SVR 训练模型的预测结果均更接近真实值, 说明本文提出的 IGWO 算法在锂电池数据集上也有着更好的寻优能力,

能够跳出 GWO 训练过程中陷入的局部最优.

将预测起点左移至循环次数为 60 处, 使得预测周期变长, 此时基于 SVR、GWO-SVR 和 IGWO-SVR 训练得到模型的 RUL 预测结果如图 6 所示. 对比可见, 在预测周期更长的场景下, 各个算法的

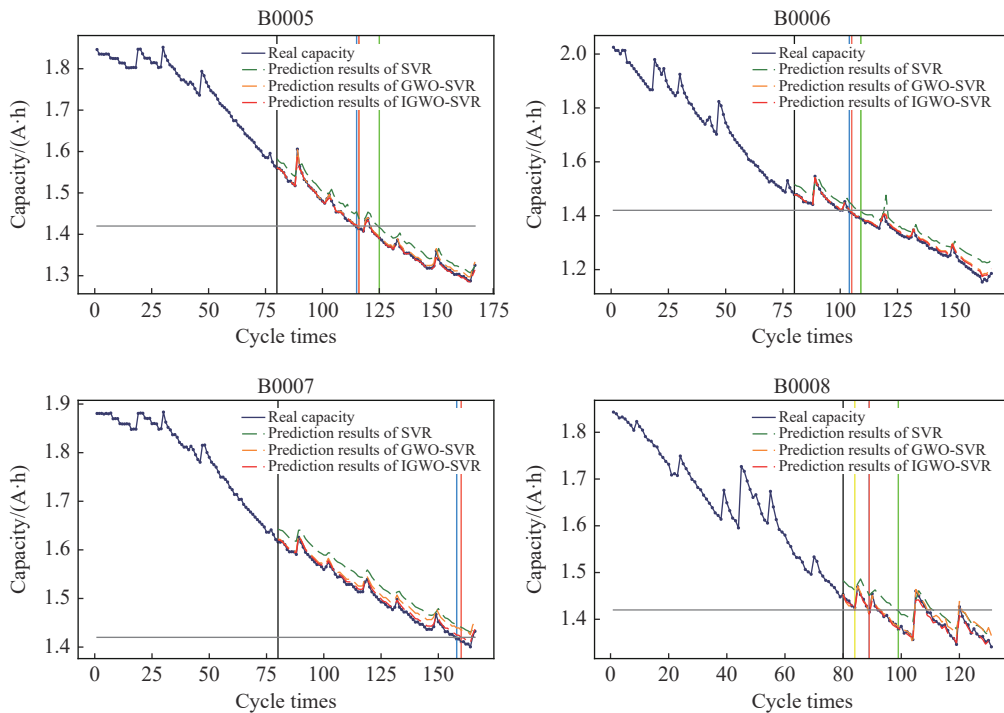


图 5 基于三种算法的锂电池 RUL 预测结果 (80 cycles)

Fig.5 RUL predictions of lithium-ion batteries based on three algorithms (80 cycles)

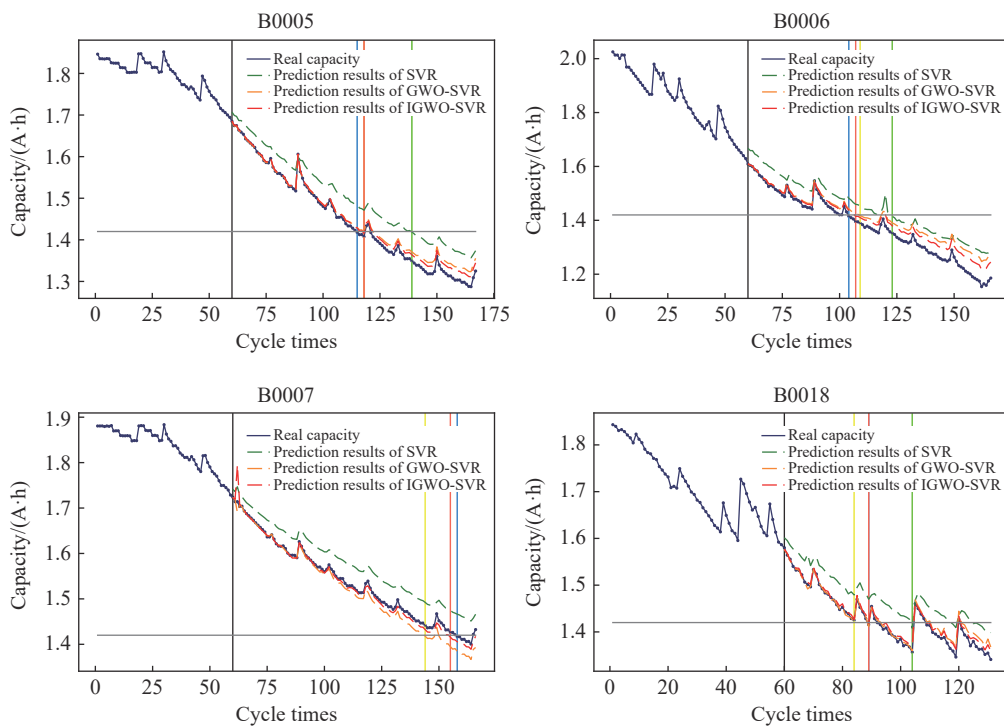


图 6 基于三种算法的锂电池 RUL 预测结果 (60 cycles)

Fig.6 RUL predictions of lithium-ion batteries based on three algorithms (60 cycles)

预测结果与真实值之间的偏差明显变大, IGWO-SVR 的预测结果相对最好, 在不同电池数据上预测的 RUL 值均最接近真实值。

统计预测起点分别为 80 次循环和 60 次循环时, 各个算法训练的模型对不同锂电池的 RUL 预测结果得到表 3。其中, RUL 一列代表各个电池的实际剩余使用寿命, RUL-P 代表相应算法的预测值, Er 则代表 RUL 和 RUL-P 之间误差的绝对值。预测起点为 80 次循环时, 对于 7 号电池, 采用 SVR 和 GWO-SVR 算法预测的 RUL 值未达到失效阈值, 因此其 RUL-P 和 Er 均用“—”表示。

可以看出, 采用 IGWO-SVR 算法取得的预测效果更好, 在 18 号电池上实现了与真实值一致的 RUL 预测结果。在预测周期最长的 7 号电池上, IGWO-SVR 算法性能优势明显, 预测误差明显更低。对于 5 号和 6 号电池, IGWO-SVR 和 GWO-SVR 的 RUL 预测结果相近。为了进一步对比三种算法的

预测精度, 统计电池容量预测结果与真实容量值之间的均方根误差 (Root mean square error, RMSE) 和平均绝对百分误差 (Mean absolute percentage error, MAPE) 值, 得到表 4。

分析表 4 数据可见, 进行参数寻优后, 不同预测起点下 SVR 算法在全部四块电池上的预测误差都显著降低, RMSE 值和 MAPE 值均降低一倍以上。在不同预测起点和电池的数据上, 使用 IGWO-SVM 取得的 RUL 预测精度均最高, 与 GWO-SVR 相比 RMSE 和 MAPE 值至少降低了 10%; 在预测起点为 80 cycle 时, IGWO-SVM 对不同电池数据的预测结果均与真实值高度接近, RMSE 值均在 1% 以内。对于 5 号和 6 号电池, 虽然 IGWO-SVM 与 GWO-SVR 的 RUL 预测结果相近, 但是 IGWO-SVM 的容量预测效果更好, 不同预测起点下的 RMSE 和 MAPE 值都显著更低。本文提出的 IGWO 算法性能较好, 在优化 SVR 参数训练锂电池 RUL

表 3 不同算法的锂电池 RUL 预测效果

Table 3 RUL predictions of lithium-ion batteries under different prediction starting points

| Prediction point | Battery | RUL | SVR   |    | GWO-SVR |    | IGWO-SVR |    |
|------------------|---------|-----|-------|----|---------|----|----------|----|
|                  |         |     | RUL-P | Er | RUL-P   | Er | RUL-P    | Er |
| 80 cycles        | B0005   | 35  | 45    | 10 | 36      | 1  | 36       | 1  |
|                  | B0006   | 24  | 29    | 5  | 25      | 4  | 25       | 4  |
|                  | B0007   | 78  | —     | —  | —       | —  | 80       | 2  |
|                  | B0018   | 9   | 19    | 10 | 4       | 5  | 9        | 0  |
| 60 cycles        | B0005   | 55  | 79    | 24 | 58      | 3  | 58       | 3  |
|                  | B0006   | 44  | 63    | 17 | 49      | 5  | 47       | 3  |
|                  | B0007   | 98  | —     | —  | 84      | 14 | 95       | 3  |
|                  | B0018   | 29  | 44    | 15 | 24      | 5  | 29       | 0  |

表 4 不同算法的容量预测误差

Table 4 Capacity prediction error of different algorithms

| Prediction point | Battery | SVR    |        | GWO-SVR |        | IGWO-SVR |        |
|------------------|---------|--------|--------|---------|--------|----------|--------|
|                  |         | RMSE/% | MAPE/% | RMSE/%  | MAPE/% | RMSE/%   | MAPE/% |
| 80 cycles        | B0005   | 2.34   | 1.59   | 0.47    | 0.28   | 0.39     | 0.16   |
|                  | B0006   | 3.73   | 2.61   | 1.21    | 0.73   | 0.91     | 0.53   |
|                  | B0007   | 2.73   | 1.78   | 1.4     | 0.86   | 0.54     | 0.34   |
|                  | B0018   | 2.67   | 1.76   | 1.13    | 0.64   | 0.63     | 0.33   |
| 60 cycles        | B0005   | 5.62   | 3.81   | 1.70    | 0.93   | 1.16     | 0.68   |
|                  | B0006   | 7.31   | 5.21   | 3.69    | 2.32   | 3.15     | 2.04   |
|                  | B0007   | 4.15   | 2.67   | 1.88    | 1.02   | 1.08     | 0.45   |
|                  | B0018   | 4.76   | 3.23   | 1.08    | 0.57   | 0.87     | 0.52   |

预测模型的应用场景, 能够取得比 GWO 算法更好的优化效果。

## 4 结论

本文基于容量增量分析等方法从锂电池充放电数据中提取并筛选得到 CC 充电时长、IC 曲线波峰面积等特征, 使用 SVR 算法训练 RUL 预测模型, 并引入 GWO 算法进行参数寻优。针对标准 GWO 算法容易陷入局部最优的问题, 对传统位置更新方程进行改写, 引入个体记忆能力提出一种改进灰狼优化算法 IGWO。开展对比试验验证提出的 IGWO 算法性能, 结论如下:

(1) 基于 19 个标准测试函数开展 IGWO 和 GWO 优化效果对比试验, 结果表明 IGWO 在寻优精度和收敛速度上均更具优势。

(2) 基于 NASA 实验室的锂电池数据集开展实验, 对比 SVR、GWO-SVR 和 IGWO-SVR 训练模型 RUL 预测效果, 证明基于 IGWO-SVR 建立的模型能够显著提升 RUL 预测精度, 在不同电池数据上的预测结果的均方根误差均下降了 10% 以上。

研究下一步考虑将提出的 IGWO 算法应用于其他机器学习算法参数寻优、大规模函数优化、约束优化等优化问题中, 进一步检验算法效果。

## 参 考 文 献

- [1] Li F Q, Sun Z, Yin S, et al. Novel LLZTO@Ag composite layer for the stable anode of sulfide all-solid-state lithium battery. *Chin J Eng*, 2023, 45(11): 1928  
(李凡群, 孙振, 阎硕, 等. 基于 LLZTO@Ag 复合层负极改性的硫化物全固态锂电池及其性能. *工程科学学报*, 2023, 45(11): 1928)
- [2] Yang Y, He Y P, Zhang P P, et al. Research progress on coating modification of lithium-rich cathode materials for lithium-ion batteries. *Chin J Eng*, 2022, 44(3): 367  
(杨溢, 何亚鹏, 张盼盼, 等. 锂离子电池富锂正极材料的包覆改性研究进展. *工程科学学报*, 2022, 44(3): 367)
- [3] Xie S, Gong Y Z, Li M H. Progress in application of Li-ion battery in civil aviation field. *Battery Bimon*, 2020, 50(4): 388  
(谢松, 巩译泽, 李明浩. 锂离子电池在民用航空领域中应用的进展. *电池*, 2020, 50(4): 388)
- [4] Che Y H, Hu X S, Lin X K, et al. Health prognostics for lithium-ion batteries: Mechanisms, methods, and prospects. *Energy Environ Sci*, 2023, 16(2): 338
- [5] Li L B, Ji L, Zhu Y Z, et al. Investigation of RUL prediction of lithium-ion battery equivalent cycle battery pack. *Chin J Eng*, 2020, 42(6): 796  
(李练兵, 季亮, 祝亚尊, 等. 等效循环电池组剩余使用寿命预测. *工程科学学报*, 2020, 42(6): 796)
- [6] NTSB. Aircraft Incident Report: Auxiliary Power Unit Battery Fire, Japan Airlines Boeing 787-8, JA829J, Boston, Massachusetts, January 7, 2013[R/OL]. *National Transportation Safety Board* (2014-11-21) [2023-05-31]. <https://www.ntsb.gov/investigations/accidentreports/reports/air1401.pdf>
- [7] Tian J Q, Xu R L, Wang Y J, et al. Capacity attenuation mechanism modeling and health assessment of lithium-ion batteries. *Energy*, 2021, 221: 119682
- [8] Li X J, Yu D, Søren Byg V, et al. The development of machine learning-based remaining useful life prediction for lithium-ion batteries. *J Energy Chem*, 2023, 82: 103
- [9] Kukurowski N, Pazera M, Witczak M. Takagi-sugeno observer design for remaining useful life estimation of Li-ion battery system under faults. *Electronics*, 2020, 9(9): 1537
- [10] Khodadadi Sadabadi K, Jin X, Rizzoni G. Prediction of remaining useful life for a composite electrode lithium ion battery cell using an electrochemical model to estimate the state of health. *J Power Sources*, 2021, 481: 228861
- [11] El Mejdoubi A, Chaoui H, Gualous H, et al. Lithium-ion batteries health prognosis considering aging conditions. *IEEE Trans Power Electron*, 2019, 34(7): 6834
- [12] Yu J B. State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble. *Reliab Eng Syst Saf*, 2018, 174: 82
- [13] Zhang J S, Jiang Y C, Li X, et al. An adaptive remaining useful life prediction approach for single battery with unlabeled small sample data and parameter uncertainty. *Reliab Eng Syst Saf*, 2022, 222: 108357
- [14] Wei M, Wang Q, Ye M, et al. An indirect remaining useful life prediction of lithium-ion batteries based on a NARX dynamic neural network. *Chin J Eng*, 2022, 44(3): 380  
(魏孟, 王桥, 叶敏, 等. 基于 NARX 动态神经网络的锂离子电池剩余寿命间接预测. *工程科学学报*, 2022, 44(3): 380)
- [15] Xu J N, Ni Y L, Zhu C B. Remaining useful life prediction for lithium-ion batteries based on improved support vector regression. *Trans China Electrotech Soc*, 2021, 36(17): 3693  
(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. *电工技术学报*, 2021, 36(17): 3693)
- [16] Zhang S Z, Zhai B Y, Guo X, et al. Synchronous estimation of state of health and remaining useful lifetime for lithium-ion battery using the incremental capacity and artificial neural networks. *J Energy Storage*, 2019, 26: 100951
- [17] Abushawish A, Jarndal A. Hybrid particle swarm optimization-grey wolf optimization based small-signal modeling applied to GaN devices. *Int J RF Mic Comp-Aid Eng*, 2022, 32(5): e23081
- [18] Wang Y T, Liu K, Zhao Y F. Flight alternate optimization scheme

- in dangerous weather based on multiexpectation. *Chin J Eng*, 2023, 45(4): 654  
(王岩韬, 刘锬, 赵焜飞. 雷暴天气下的多航班备降动态优化方案. 工程科学学报, 2023, 45(4): 654)
- [19] Wang Q, Ye M, Wei M, et al. ELM- and MCSCKF-based state of charge estimation for lithium-ion batteries. *Chin J Eng*, 2023, 45(6): 995  
(王桥, 叶敏, 魏孟, 等. 基于 ELM 和 MCSCKF 的锂离子电池 SOC 估计. 工程科学学报, 2023, 45(6): 995)
- [20] Banaie-Dezfouli M, Nadimi-Shahraki M H, Beheshti Z. BE-GWO: Binary extremum-based grey wolf optimizer for discrete optimization problems. *Appl Soft Comput*, 2023, 146: 110583
- [21] Cai Z X, Dang Z, Lü Y, et al. Adaptive dynamic mode decomposition and GA-SVM with application to fault classification of planetary bearing. *Chin J Eng*, 2023, 45(9): 1559  
(蔡志鑫, 党章, 吕勇, 等. 自适应动模式分解和 GA-SVM 在行星轴承故障分类中的应用. 工程科学学报, 2023, 45(9): 1559)
- [22] Liu Y Z, Jiang Y, Zhang X, et al. An improved grey wolf optimizer algorithm for identification and location of gas emission. *J Loss Prev Process Ind*, 2023, 82: 105003
- [23] Dridi F, El Assad S, El Hadj Youssef W, et al. Design, hardware implementation on FPGA and performance analysis of three chaos-based stream ciphers. *Fractal Fract*, 2023, 7(2): 197
- [24] Li J A, An Q, Lei H, et al. Survey of lévy flight-based metaheuristics for optimization. *Mathematics*, 2022, 10(15): 2785
- [25] Bian X L, Wei Z B, Li W H, et al. State-of-health estimation of lithium-ion batteries by fusing an open circuit voltage model and incremental capacity analysis. *IEEE Trans Power Electron*, 2022, 37(2): 2226
- [26] Zhang S, Wang Y H. An improved software defect prediction model based on grey incidence analysis and Naive Bayes algorithm. *J Intell Fuzzy Syst*, 2022, 43(5): 6047