**DOI**：10.13234/j.issn.2095-2805.2025.6.320 **中图分类号**：TM53 **文献标志码**：A

# 基于改进支持向量回归的超级电容器寿命预测

刘晓明，任宇朋(中国电源学会会员)，陈 海，冯大伟，田 俊
(河北工业大学电气工程学院，天津 300401)

**摘要**：超级电容器作为1种新型储能器件，其服役性能与剩余寿命会影响其所在系统的可靠性。以2.7 V/10 F超级电容器为研究对象，搭建了储能器件老化实验与测试平台，通过采集超级电容器的特征量变化，分析其性能退化规律和影响因素。为了解决超级电容器寿命预测训练集小样本和预测精度之间的矛盾，提出了1种精英保留策略的非支配排序遗传算法II NSGA-II(non-dominated sorting genetic algorithm II)与支持向量回归SVR(support vector regression)相结合的寿命预测方法；确定了将充放电循环次数和充放电时长均值作为超级电容性能退化的表征量；建立了训练集样本最小和预测精度最高的双目标模型。相比于神经网络BP(back propagation)、SVR和长短期记忆网络LSTM(long short-term memory)方法，所提NSGA-II-SVR方法在超级电容器寿命预测中，可实现样本训练集数量小的前提下，预测均方根误差和平均绝对百分比误差评价指标均提升5~10倍。最后使用NASA提供的锂离子电池开源数据集进行泛化性实验，证明了NSGA-II-SVR方法具有较强的泛化能力。

**关键词**：超级电容器；剩余寿命；非支配排序遗传算法II；支持向量回归；训练集

# Life Prediction of Supercapacitor Based on Improved Support Vector Regression

LIU Xiaoming, REN Yupeng, *Member*, *CPSS*, CHEN Hai, FENG Dawei, TIAN Jun
(School of Electrical Engineering, Hebei University of Technology, Tianjin 300401, China)

**Abstract:** The service performance and remaining life of a supercapacitor which serves as a novel energy storage device are part of the factors affecting the operation reliability of a system. A 2.7 V/10 F supercapacitor was taken as the research object, an aging experiment and test platform for energy storage devices was built, and the rules for the performance degradation of the supercapacitor and influencing factors were analyzed by collecting the variations in its characteristics. To solve the contradictory relationship between small samples and prediction accuracy of the supercapacitor lifetime prediction training set, a lifetime prediction method combining the non-dominated sorting genetic algorithm II (NSGA-II) with an elite retention strategy and support vector regression (SVR) was proposed, and the average values of charge-discharge cycles and charge-discharge duration were determined as the characterization of supercapacitor performance degradation. Moreover, a dual-objective model with the minimum sample size and highest prediction accuracy in the training set was established. Compared with the BP(back propagation), SVR and LSTM(long short-term memory) methods, the proposed NSGA-II-SVR method improved the evaluation indicators of root mean square error and mean absolute percentage error by 5 to 10 times in supercapacitor lifetime prediction under the premise of a small sample size of the training set. Finally, a generalization experiment was carried out using the open-source data set of lithium-ion batteries provided by NASA, proving that the NSGA-II-SVR method has strong generalization capability.

**Keywords:** Supercapacitor; remaining life; non-dominated sorting genetic algorithm II (NSGA-II); support vector regression (SVR); training set

**收稿日期**：2022-11-09；**修回日期**：2023-02-07；**录用日期**：2023-03-02；**网络首发日期**：2023-04-13
**基金项目**：河北省省级科技计划资助项目(E2021202186，E2020202086)
This work is supported by Science & Technology Program of Hebei Province under the grants E2021202186 and E2020202086

目前，超级电容器性能介于传统电容器与二次电池之间[1]。因其具有充放电速度快、循环寿命长及工作温度范围宽[2-3]等优点，可作为新型电力系统智能感知与调控设备的信号源，以满足系统智能化的要求。超级电容器的运行性能受到外部应力和器件材料等因素的影响[4-5]，导致超级电容器寿命远低于其理论值。因此，为确保其所在系统的运行稳定性和可靠性，有必要对超级电容器的服役性能和剩余寿命进行检测与评估。

对于超级电容器寿命预测的研究方法分为基于模型和基于数据驱动 2 类。基于模型的预测方法主要依据失效机理和老化过程中电容器参数变化所建立的模型。文献[6]通过拟合固体电极界面层老化规律，建立了容量衰减模型，研究了温度和电压对固体电极的界面老化规律参数的影响；文献[7]考虑温度和电压影响，基于经验法则，预测了超级电容器的退化特征参数；文献[8]对超级电容器单体等效电路模型、热模型和寿命估算模型进行参数辨识，误差在 2%以内。基于数据驱动的方法则无需考虑超级电容器内部物理过程，通过模拟数据与组件退化的非线性关系进行预测。文献[9]采用模糊-神经网络法对超级电容容量和内阻进行了预测；文献[10]采用混合遗传算法 HGA(hierarchical genetic algorithm)优化长短时记忆神经网络 LSTM(long short-term memory)，预测了超级电容器的容量；文献[11]采用粒子群算法 PSO(particle swarm optimization)优化支持向量回归 SVR(support vector regression)，预测了超级电容器的容量以及内阻老化趋势。

基于上述分析，为了解决基于模型预测方法中反映服役周期内的性能指标参数退化数据样本不足，基于数据驱动预测方法预测精度依赖于器件老化大样本数据，且存在训练集数量取值不精确的问题，提出了 1 种带精英策略的非支配排序遗传算法 II NSGA-II(non-dominated sorting genetic algorithm II)与支持向量回归 SVR 组合方法 NSGA-II-SVR，除了 SVR 惩罚参数$\beta$和核函数$\delta$，将训练集数量 $a$ 作为 1 种新的优化变量，建立了训练集数量和预测误差同时达到最小的双目标模型。通过对实验数据的验证分析，表明所提出的 NSGA-II-SVR 能够找到训练集数量与预测误差的最优组合，用以实现以最少样本实现性能退化数据的寿命预测。

## 1　超级电容器老化实验

### 1.1　实验平台的搭建

选用 2.7 V/10 F 超级电容单体进行充放电测试，超级电容器测试系统(测试电压范围为 0~5 V，电流范围为±6 A)如图 1 所示。此系统可对超级电容进行不同充放电工作模式的操作，采集充放电循环次数、充放电电压(电流)及充放电时间等外特征量，与可控恒温恒湿试验箱相结合，实现特定温度下超级电容充放电测试。



**图 1　超级电容器测试系统**

**Fig. 1 Supercapacitor test system**

依据 QC/T741—2014《车用超级电容器》，结合所研究超级电容器的工况要求，确定容量测试路线如下。

**步骤一** 以恒值充电电流 $I_1$ 充电至额定电压 $U_R$，采集单次充电时间 $t_1$。

**步骤二** 以恒值放电电流 $I_2$ 放电至最低电压 $U_{min}$，采集单次放电时间 $t_2$ 和电容器电压从 80%$U_R$ 至 $U_{min}$ 的放电时间 $t$。

**步骤三** 求得每次循环电容器单体容量值为

$$C = I_2 \cdot t / (0.8U_R - U_{min}) \tag{1}$$

**步骤四** 为加速老化过程，根据 DL/T1652—2016《电能计量设备用超级电容器技术规范》，将可控恒温恒湿箱设置为 70 ℃，进入恒电流循环充放电模式。当容量达到寿命失效阈值时(设定容量为初始容量的 85%)，则终止实验。

**步骤五** 依据工况条件，采用周期性间歇工作

制，设定每循环 10 000 次，将样品静置 12 h；再重复上述实验过程。

通过以上实验研究，得到 4 类超级电容器实测容量退化曲线如图 2 所示。可以看出，超级电容器容量退化呈非线性衰减趋势，老化过程中出现了容值增加现象。分析其原因，是加速老化实验中采用了间歇式实验方式，其内部电荷经历了再分配的动态变化过程。

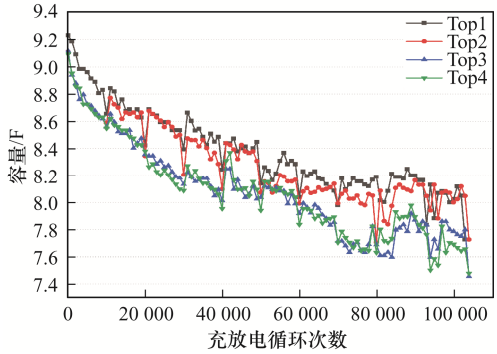



**图 2 超级电容器容量退化曲线**

**Fig. 2 Capacity degradation curves for supercapacitors**

## 2 超级电容器老化特征量提取与分析

为了解决超级电容器实际运行中，容量及内阻等性能退化参数获取难且易受干扰的难题，采用充放电电压、电流及循环次数等外特征量，用以间接表征超级电容器性能的动态变化。为此，有必要建立外特征量与其性能退化之间相关性的表达式。

超级电容器全寿命循环周期中，充放电电压、电流及循环周期次数易于监测并获取。充放电过程分为恒流充电和恒流放电阶段。在恒流充电阶段，当超级电容器端电压 $U$ 与充电电流 $I_1$ 确定后，超级电容器储存的总电荷量为

$$Q = CU = I_1 t_1 \tag{2}$$

由式(2)可求得超级电容器容量与充电时间存在线性关系。以超级电容器 Top4 为例，实验得到了恒流充电阶段所需时间与超级电容器容量关系曲线，如图 3 所示。结果表明，从最低截止电压到最高额定电压充电所需时间与超级电容器容量存在近似线性的强相关关系；在恒流放电阶段，即从最高额定电压放电到最低截止电压，所需时间 $t_2$ 也可间接表征超级电容器的性能退化。

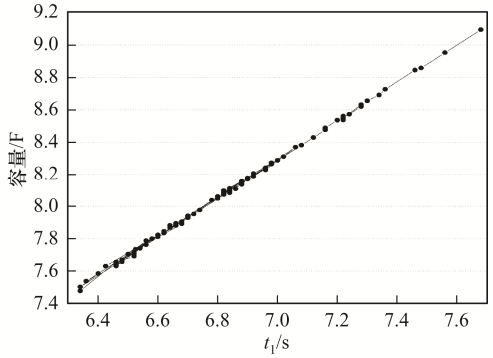



**图 3 恒流充电阶段时间与容量关系曲线**

**Fig. 3 Curve of relationship between time and capacity at constant-current charging stage**

基于上述分析，确定将恒流充电时间与恒流放电时间的平均值，作为表征超级电容器性能退化的第 1 个外特征量，设为 $\boldsymbol{H}_1$，即

$$\boldsymbol{H}_1 = \frac{1}{2}(t_1 + t_2) \tag{3}$$

伴随超级电容器充放电循环次数的增加，其充放电循环能力逐渐下降，内部阻抗不断增加，容量不断衰减，导致超级电容器性能失效。为此，将充放电循环次数作为表征超级电容器性能退化的第 2 个外特征量，设为 $\boldsymbol{H}_2$。

采用 Pearson 及 Spearman 相关系数定性分析 2 个外特征量 $\boldsymbol{H}_1 = \{H_{1i}\}_{i=1}^{n}$、$\boldsymbol{H}_2 = \{H_{2i}\}_{i=1}^{n}$ 与本体容量 $\boldsymbol{C} = \{C_i\}_{i=1}^{n}$ 的相关性。Pearson 相关系数和 Spearman 相关系数分别为

$$P = \frac{E(\boldsymbol{H}_1\boldsymbol{C}) - E(\boldsymbol{H}_1)E(\boldsymbol{C})}{\sqrt{E(\boldsymbol{H}_1^2) - (E(\boldsymbol{H}_1))^2}\sqrt{E(\boldsymbol{C}^2) - (E(\boldsymbol{C}))^2}} \tag{4}$$

$$S = \frac{\sum_i (H_{1i} - \bar{H}_1)(C_i - \bar{C})}{\sqrt{\sum_i (H_{1i} - \bar{H}_1)\sum_i (C_i - \bar{C})^2}} \tag{5}$$

式中：$E()$为期望值；$\bar{H}_1$ 和 $\bar{C}$ 分别为 $\boldsymbol{H}_1$ 和 $\boldsymbol{C}$ 的平均值；$C_i$ 为超级电容器实际电容值；$S \geqslant -1$，$P \leqslant 1$，其绝对值越大，相关程度越强。

所提取的 2 个外特征量分别与其本体容量之间的相关系数见表 1。可以看出，超级电容器的 2

个外特征量与本体容量之间的相关系数绝对值范围为[0.900 0, 1.000 0]，所提取的表征超级电容器性能退化的外特征量与容量之间存在强相关性。

**表 1　Pearson 及 Spearman 相关系数**

**Tab. 1 Pearson and Spearman correlation coefficients**

| 电容类别 | Pearson 系数 | | Spearman 系数 | |
|---|---|---|---|---|
| | $\boldsymbol{H}_1$ | $\boldsymbol{H}_2$ | $\boldsymbol{H}_1$ | $\boldsymbol{H}_2$ |
| Top1 | 0.995 9 | −0.920 9 | 0.993 0 | −0.939 9 |
| Top2 | 0.996 3 | −0.902 2 | 0.998 4 | −0.926 3 |
| Top3 | 0.999 7 | −0.922 7 | 0.998 8 | −0.941 3 |
| Top4 | 0.999 6 | −0.920 1 | 0.999 0 | −0.925 3 |

基于上述分析，将超级电容器充放电时间平均值与充放电循环次数作为表征容量退化特性的特征参量。

## 3　NSGA-II-SVR 寿命预测的实现与分析

### 3.1　支持向量机回归方法

基于第 2 节分析，超级电容器性能退化数据集呈现基于时间序列的特征。为了实现小样本高精度预测超级电容器剩余寿命的目标，有必要采用支持向量机回归方法。在机器学习算法中，SVR 方法在处理小样本数据、非线性及时间序列等问题时具有优势，且泛化能力强[12]。支持向量 SVR 的数据集为

$$D=\{(H_i,C_i)\}_{i=1}^{n}\in R^n\times R,\ \ i=1,2,\cdots,a,\cdots,n \tag{6}$$

对于式(6)，$\boldsymbol{H}=\{H_{1i},H_{2i}\}_{i=1}^{n}$ 为超级电容器外特征量，为输入向量；$\boldsymbol{C}=\{C_i\}_{i=1}^{n}$ 为对应输出向量。对于非线性问题，SVR 通过非线性映射将训练集数据映射到 1 个高维特征空间，在高维特征空间进行线性回归。定义非线性映射

$$f_c(\boldsymbol{H})=\omega\Phi(\boldsymbol{H})+b \tag{7}$$

式中：$\Phi(\boldsymbol{H})$为非线性映射函数；$f_c(\boldsymbol{H})$为训练样本回归预测值；$\omega$ 为权重；$b$ 为截距。$\omega$、$b$ 取值影响 SVR 回归精度。为使式(7)结构化风险最小，引入松弛变量因子 $\xi_i$、$\xi_i^*$，根据统计学结构化风险准则，将线性回归求解问题转化为优化问题形式，即

$$\min R(\omega,b,\xi)=\frac{1}{2}\|\omega\|^2+\beta\sum_{i=1}^{n}(\xi_i+\xi_i^*) \tag{8}$$

$$\begin{cases}C_i-\omega\Phi(H_i)-b\leqslant\varepsilon+\xi_i\\ \omega\Phi(H_i)+b-C_i\leqslant\varepsilon+\xi_i^*\\ \xi_i,\xi_i^*\geqslant 0\end{cases} \tag{9}$$

式中：$\beta$为惩罚参数，权衡样本拟合误差和回归模型复杂度；$\varepsilon$ 为不敏感损失因子(允许的最大误差)，$\varepsilon$>0。

引入拉格朗日乘法算子，式(8)可转换为

$$\begin{aligned}\max R(\alpha_i^*,\alpha_i)=&-\frac{1}{2}\sum_{i,j}^{n}(\alpha_i^*-\alpha_i)\cdot\\ &(\alpha_j^*-\alpha_j)\Phi(H_i)\Phi(H_j)-\\ &\sum_{i}^{n}\alpha_i(C_i+\varepsilon)+\sum_{i}^{n}\alpha_i^*(C_i-\varepsilon)\end{aligned} \tag{10}$$

$$\text{s.t.}\begin{cases}\sum_{i}^{n}(\alpha_i-\alpha_i^*)=0\\ 0<\alpha_i,\alpha_i^*<\beta\end{cases} \tag{11}$$

式中，$\alpha_i$和 $\alpha_i^*$为拉格朗日乘数。根据 Mercer 定理法则，求解上述凸二次规划问题并获得非线性映射 SVR 表达式为

$$f_c(\boldsymbol{H})=\omega\Phi(\boldsymbol{H})+b=\sum_{i}^{n}(\alpha_i-\alpha_i^*)K(H_i,\boldsymbol{H}) \tag{12}$$

式中，$K(H_i,\boldsymbol{H})$ 为核函数。选取径向基函数 RBF (radial basis function)的核函数为

$$K(H_i,\boldsymbol{H})=\mathrm{e}^{\left(\frac{\|H_i-\boldsymbol{H}\|^2}{2\delta^2}\right)} \tag{13}$$

基于上述 SVR 数学公式推导，惩罚参数$\beta$和核参数 $\delta$ 决定着 SVR 回归拟合性能。在实际应用中，应使用较少训练集数量 $a$(超级电容器历史工作数据)充分学习完成模型训练过程后准确预测超级电容器剩余寿命。为此，本文将训练集数量 $a$ 作为 1 种新优化变量，引入多目标优化算法 NSGA-II 来优化 SVR 的相关参数，以实现同时满足训练集数量最少样本和预测精度最高的双目标要求。

### 3.2　NSGA-II 算法

NSGA-Ⅱ算法[13]是 1 种用于解决多目标优化问题的多目标优化算法。该算法是在寻找最优解的

迭代过程中每一代种群个体间根据其支配关系进行非支配排序；个体序值越小，越接近于最优解。由于存在非支配排序序值相同的个体，引入拥挤度概念，选择拥挤度较小的个体。同时，算法引进了精英策略，将每代进化后得到的规模为 $N$ 的子代种群与规模为 $N$ 的父代种群合并形成规模为 $2N$ 的种群；再对该种群中个体重新进行非支配排序和拥挤度计算，选择最优规模为 $N$ 的种群，以保证迭代过程中前代优良个体的保存。

基于上述分析，针对 SVR 方法存在训练集数量与回归拟合精度之间的矛盾关系问题，提出 NSGA-II 与 SVR 组合的方法，以实现最少训练集，且高回归拟合精度。

### 3.3 NSGA-II-SVR 组合的寿命预测方法

NSGA-II-SVR 方法实施流程如图 4 所示，实施过程如下。

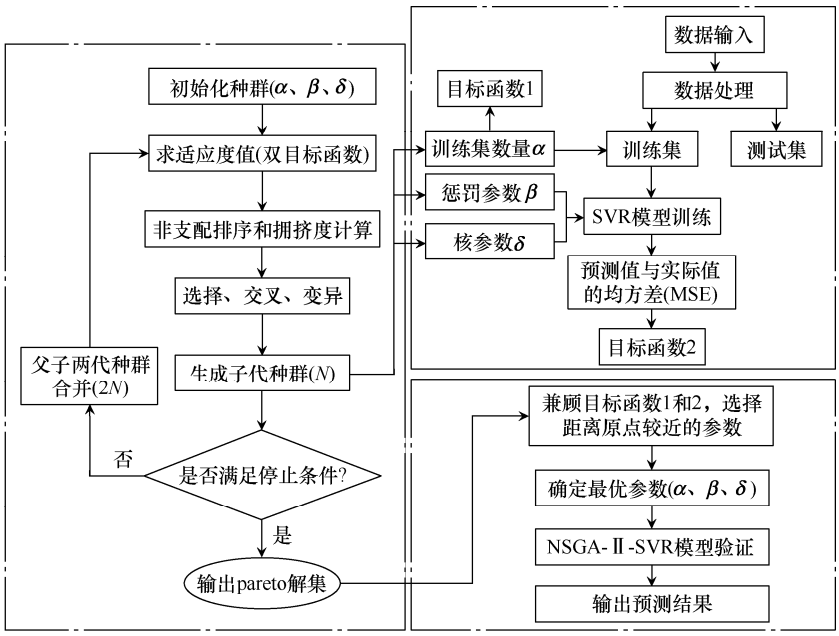



**图 4 NSGA-II-SVR 预测实施过程**

**Fig. 4 Implementation process of NSGA-II-SVR prediction**

**步骤一** 性能退化数据集归一化处理。将充放电循环次数、充放电时间平均值及本体容量整合为数据集，归一化处理。为减小计算量，每隔 1 000 次充放电循环取值一次。根据目标函数 $f_1(a)$，构建训练集和测试集。

**步骤二** 设置目标函数。以 SVR 训练集数量为目标函数 $f_1(a)$，利用实际容量和 SVR 预测值之间的均方差 MSE(mean square error)作为预测误差建立目标函数 $f_2(\beta,\delta)$，即

$$\begin{cases} f_1(a)=a \\ f_2(\beta,\delta)=\dfrac{1}{n}\sum_i^n (C_i^*-C_i)^2 \end{cases} \tag{14}$$

式中，$C_i^*$ 为超级电容器预测电容值。

**步骤三** 设置双目标优化参数。选取种群规模为 30，最大迭代次数为 200，变量数量为 3，目标函数数量为 2。

**步骤四** 进入 NSGA-II-SVR 寻优流程。采用 NSGA-II 算法，以目标函数 $f_1(a)$ 和 $f_2(\beta,\delta)$ 同时最小对 SVR 参数进行寻优、迭代，直至满足停止条件；输出 Pareto 解集曲线；选择最优 Pareto 解，得到最佳参数。

**步骤五** 确定停止条件。假设 2 个 Pareto 解集相隔 GAP(表示相隔代数)，则称这 2 个种群为相邻 GAP 代种群。若相邻 GAP 代种群距离小于可接受相邻 GAP 代种群最小距离，则视为趋于稳定，且连续 $T$ 次保持这种稳定则算法停止[14]。GAP 和 $T$ 的取值会影响算法的计算量和降低迭代次数。本文中，GAP 设定为 5，$T$ 设定为 10。

## 4　剩余寿命预测算法对比分析

为验证 NSGA-II-SVR 方法对超级电容器寿命预测的有效性和准确性，利用性能退化数据测试集进行验证，并应用其他超级电容器寿命预测方法对超级电容器寿命进行同步预测，以对比分析预测结果。以容量预测值与实际值的均方根误差 RMSE(root mean square error)、平均绝对百分比误差 MAPE(mean absolute percentage error)和相关系数 $R$ 作为评价剩余寿命预测方法的性能评价标准，其计算公式分别为

$$R_{\mathrm{MSE}}=\sqrt{\frac{1}{n}\sum_{i}^{n}(C_i^*-C_i)^2} \tag{15}$$

$$M_{\mathrm{APE}}=\frac{1}{n}\sum_{i}^{n}\left|\frac{C_i^*-C_i}{C_i}\right| \tag{16}$$

$$R=\frac{\sum_{i}^{n}(C_i-\overline{C})(C_i^*-\overline{C^*})}{\sqrt{\sum_{i}^{n}(C_i-\overline{C})^2\sum_{i}^{n}(C_i^*-\overline{C^*})^2}} \tag{17}$$

式中，$\overline{C^*}$ 为预测容值平均值。

### 4.1　NSGA-II-SVR 方法预测结果与对比分析

4 类超级电容器 NSGA-II-SVR 方法训练集数量 $a$ 和预测误差同时最小的最优组合选取见表 2，将参数最优解引入 SVR 中并以测试集验证输出预测结果。Pareto 解集如图 5 所示。

**表 2　NSGA-II-SVR 方法的最优组合解**

**Tab. 2 Optimal combination solutions of NSGA-II-SVR method**

| 电容类别 | $a$ | 迭代次数 | $\beta$ | $\delta(\times10^{-2})$ | MSE/ $F^2(\times10^{-4})$ |
|---|---|---|---|---|---|
| Top1 | 34 | 35 | 100.000 | 3.433 | 5 414 |
| Top2 | 37 | 46 | 99.724 | 17.953 | 2 934 |
| Top3 | 43 | 53 | 100.000 | 2.197 | 1 468 |
| Top4 | 35 | 50 | 82.998 | 3.863 | 2 140 |

选用 PSO-SVR 方法和 HGA-LSTM 方法与本文所提方法进行比对。PSO-SVR 采用粒子群算法改善了支持向量机回归的性能，具有较好的预测性能。HGA-LSTM 方法将遗传算法与序列二次规划

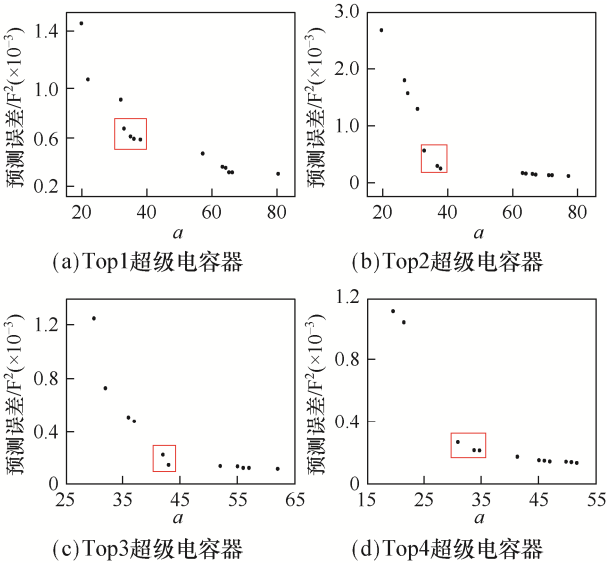



**图 5　NSGA-II-SVR 的 Pareto 解集**

**Fig. 5 Pareto solution set of NSGA-II-SVR**

算法 SQP(sequential quadratic programming)相结合，改善了遗传算法易陷入局部最优解的问题，又结合具有长期记忆能力的 LSTM，更容易学习样本数据规律。采用控制变量法，以 NSGA-II-SVR 所确定训练集数量、种群规模、迭代次数和其他参数应用于 SVR、PSO-SVR 和 HGA-LSTM，其他参数设置[10-11]见表 3。预测结果对比如图 6 所示。可知，对于 Top2、Top3、Top4 这 3 类超级电容器来说，NSGA-II-SVR 预测方法所得到 RMSE 均在 0.018 F 以下，MAPE 不超过 0.18%，相关系数 $R$ 均在 0.998 以上。采用 SVR、PSO-SVR、NSGA-II-SVR 方法进行超级电容器寿命预测，误差依次减小，表明通过合适的寻优算法优化 SVR 参数有助于提高回归预测精度。

**表 3　各种预测方法参数设置**

**Tab. 3 Parameter setting of various prediction methods**

| 预测算法 | 参数设置 |
|---|---|
| SVR | $\beta$=10，$\delta$=0.01 |
| PSO-SVR[11] | 学习因子 $l_1$=1.5、$l_2$=1.7 |
| HGA-LSTM[10] | 学习率初始值为 0.005，下降因子为 0.8，下降周期为 100 |

不同寿命预测方法的预测性能见表 4。对于 4 类超级电容器来说，NSGA-II-SVR 方法的 RMSE、MAPE 约为 HGA-LSTM 方法的 1/7~1/3，表明 SVR

方法在小样本数据分析中更有优势。

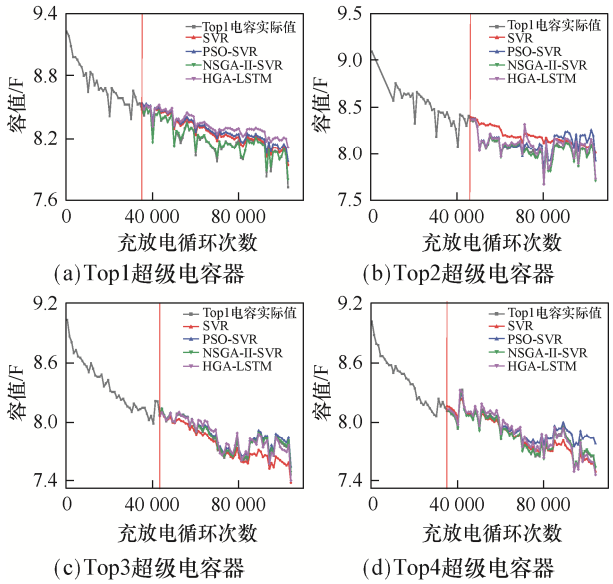



**图 6 超级电容器剩余寿命预测结果**

**Fig.6 Prediction results of remaining life of supercapacitor**

**表 4 超级电容器剩余寿命预测结果评价指标**

**Tab. 4 Evaluation indexes for remaining life prediction results of supercapacitors**

| 类别 | 预测方法 | RMSE/F | MAPE/% | *R* |
|---|---|---|---|---|
| Top1 | SVR | 0.089 7 | 0.876 8 | 0.945 96 |
| | PSO-SVR | 0.110 4 | 1.148 5 | 0.944 52 |
| | NSGA-II-SVR | 0.024 9 | 0.217 6 | 0.989 65 |
| | HGA-LSTM | 0.153 2 | 1.655 3 | 0.945 24 |
| Top2 | SVR | 0.374 3 | 3.178 4 | 0.597 23 |
| | PSO-SVR | 0.105 3 | 1.092 3 | 0.986 92 |
| | NSGA-II-SVR | 0.017 1 | 0.174 1 | 0.999 19 |
| | HGA-LSTM | 0.056 7 | 0.480 1 | 0.991 29 |
| Top3 | SVR | 0.111 1 | 1.073 8 | 0.929 33 |
| | PSO-SVR | 0.036 7 | 0.391 3 | 0.997 39 |
| | NSGA-II-SVR | 0.015 8 | 0.160 8 | 0.998 25 |
| | HGA-LSTM | 0.039 9 | 0.399 6 | 0.975 62 |
| Top4 | SVR | 0.061 1 | 0.607 1 | 0.959 71 |
| | PSO-SVR | 0.104 2 | 0.981 3 | 0.978 37 |
| | NSGA-II-SVR | 0.014 6 | 0.144 6 | 0.998 21 |
| | HGA-LSTM | 0.049 6 | 0.565 6 | 0.981 12 |

为进一步验证 SVR 在超级电容器剩余寿命预测的优越性，将 BP 神经网络和 LSTM 神经网络分别用 NSGA-II 算法优化并对寿命预测结果进行对比分析。Pareto 解集和最优组合解如图 7、图 8 和表 5 所示。对比分析可知：(1)NSGA-II-SVR 预测超级电容器剩余寿命所需要训练集数量、迭代次数和预测误差均比另 2 种方法小；(2)虽然对于 Top2 类超级电容器来说，NSGA-II-SVR 预测误差比 NSGA-II-BP 预测误差略大 $1.2405\times10^{-5}$ $F^2$，但训练集数量仅为 37 组，比 NSGA-II-BP 所需训练集数量少 22 组；(3)NSGA-II-SVR 在训练集数量为 38 组时，预测误差为 $2.48\times10^{-4}$ $F^2$，比 NSGA-II-BP 预测误差小 $3.12\times10^{-5}$ $F^2$。

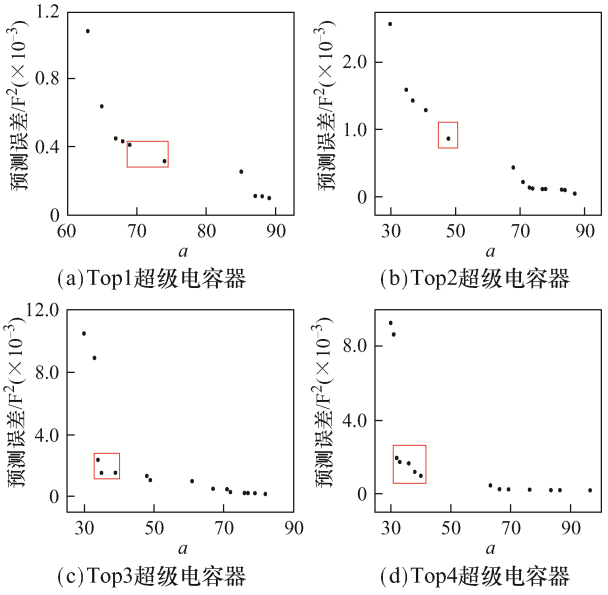



**图 7 NSGA-II-LSTM 的 Pareto 解集**

**Fig. 7 Pareto solution set of NSGA-II-LSTM**

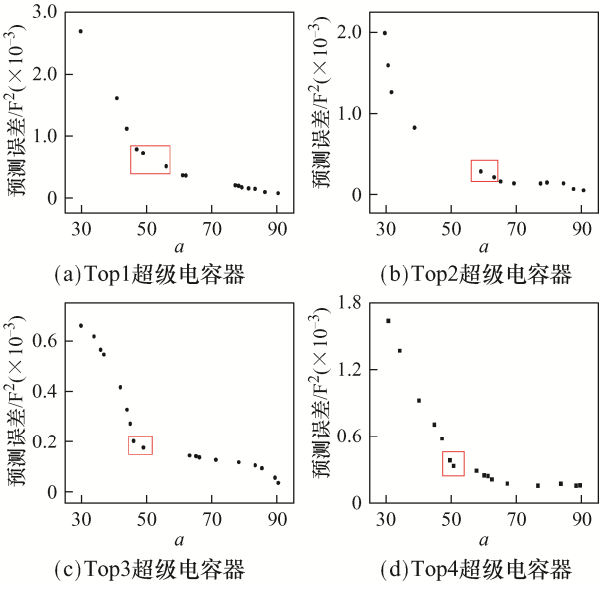



**图 8 NSGA-II-BP 的 Pareto 解集**

**Fig. 8 Pareto solution set of NSGA-II-BP**

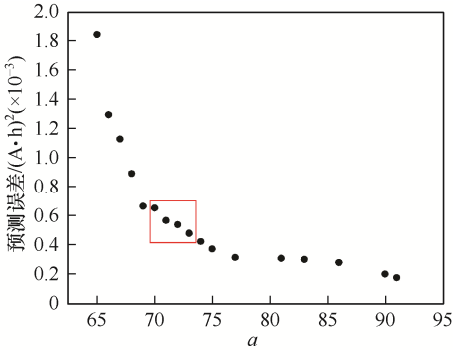
**表 5　3 种方法的最优组合解**

**Tab. 5 Optimal combination solutions of three methods**

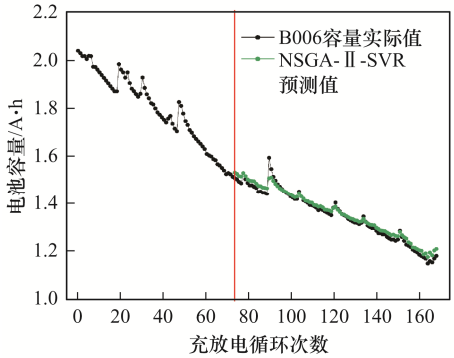
| 类别 | 预测方法 | $a$ | 迭代次数 | MSE/$F^2(\times10^{-4})$ |
|---|---|---|---|---|
| Top1 | NSGA-II-SVR | 34 | 35 | 5 414 |
| | NSGA-II-LSTM | 74 | 79 | 3 149 |
| | NSGA-II-BP | 49 | 122 | 7 207 |
| Top2 | NSGA-II-SVR | 37 | 46 | 2 934 |
| | NSGA-II-LSTM | 48 | 60 | 8 571 |
| | NSGA-II-BP | 59 | 86 | 2 792 |
| Top3 | NSGA-II-SVR | 43 | 53 | 1 468 |
| | NSGA-II-LSTM | 49 | 107 | 1 200 |
| | NSGA-II-BP | 49 | 169 | 1 685 |
| Top4 | NSGA-II-SVR | 35 | 50 | 2 140 |
| | NSGA-II-LSTM | 40 | 46 | 9 814 |
| | NSGA-II-BP | 53 | 124 | 2 916 |

### 4.2 模型泛化验证

为了验证本文所提出的 NSGA-II-SVR 预测模型的泛化性，使用美国国家航空航天局卓越预测中心 NASA 提供的锂电池数据集进行验证。该实验数据的研究对象是容量为 2 A·h 的 18650 钴酸锂电池，与超级电容器老化趋势不同，所以选用此数据可以更好地反应预测模型在同类任务中的适用性。选取 B0006 电池的数据进行验证，根据文献[15]以恒流放电过程中提取等压降放电时间作为 NSGA-II-SVR 预测模型的输入量，B0006 电池容量作为输出量。Pareto 解集和预测结果如图 9 所示。由图 9(a)可以得到 NSGA-II-SVR 预测 B0006 电池寿命的最优组合解为训练集数量 $a=73$、惩罚参数$\beta=85.101$、核参数$\delta=1.0\times10^{-3}$。预测结果的 RMSE、MAPE 和 $R$ 分别为 0.021 876A·h、1.676 2%、0.988 5，预测效果较好，可以证明 NSGA-II-SVR 具有较强的泛化能力。




(a)B0006的Pareto解集




(b)B0006的预测结果

**图 9　NSGA-II-SVR 泛化实验结果**

**Fig. 9 Results of generalization experiment for NSGA-II-SVR prediction model**

## 5　结语

以 2.7 V/10 F 超级电容器为研究对象，搭建高温加速老化实验测试平台；利用 Pearson 及 Spearman 相关系数法，得到了充放电时间平均值与充放电循环次数 2 个外特征量 $\boldsymbol{H}$ 与本体容量 $\boldsymbol{C}$ 之间具有强相关的非线性关系，以此构建了超级电容器性能退化数据集。利用超级电容器性能退化数据集，以外特征量 $\boldsymbol{H}$ 为输入向量，容值 $\boldsymbol{C}$ 为对应的输出向量，相较于其他超级电容器寿命预测方法的预测结果，NSGA-II-SVR 能够实现少训练样本数据和高精度寿命预测的双目标要求。通过 NSGA-II 分别寻优 SVR、LSTM 和 BP，比对预测结果，NSGA-II-SVR 所需训练集数量和预测误差均小于另 2 种方法，验证了所提出改进方法在预测超级电容器剩余寿命方面具有优势。利用 NASA 的锂电池老化数据集，进一步验证了本文所提 NSGA-II-SVR 寿命预测方法具有较强的泛化性。

**参考文献：**

[1] Wang Kai, Wang Wanli, Wang Licheng, et al. An improved SOC control strategy for electric vehicle hybrid energy storage systems [J]. Energies, 2020, 13(20): 5297.

[2] Raza W, Ali F, Raza N, et al. Recent advancements in supercapacitor technology [J]. Nano Energy, 2018, 52:

441-473.

[3] 王萌, 黄细霞, 孙程. 面向脉冲负载的基于超级电容储能 UPQC 设计及控制策略研究[J]. 电源学报, 2024, 22(2): 231-241.
Wang Meng, Huang Xixia, Sun Cheng. Research on design and control strategy for UPQC based on supercarpacitor energy storage for pulse load [J]. Journal of Power Supply, 2024, 22(2): 231-241. (in Chinese)

[4] Rizoug N, Bartholomeus P, Le Moigne P. Study of the ageing process of a supercapacitor module using direct method of characterization [J]. IEEE Transactions on Energy Conversion, 2012, 27(2): 220-228.

[5] 王珏. 基于超级电容储能的 SiC 器件变流器性能分析[J]. 电源学报, 2023, 21(2): 172-178.
Wang Jue. Performance analysis of SiC device converter based on super capacitor energy storage [J]. Journal of Power Supply, 2023, 21(2): 172-178. (in Chinese)

[6] German R, Sari A, Venet P, et al. Prediction of supercarpacitors floating ageing with surface electrode interface based ageing law [J]. Microelectronics Reliability, 2014, 54(9-10): 1813-1817.

[7] 吴立锋, 单金生, 关永, 等. 一种考虑温度和电压的超级电容寿命预测方法[J]. 电源技术, 2018, 42(1): 90-92, 96.
Wu Lifeng, Shan Jinsheng, Guan Yong, et al. Life prediction method of supercapacitor for considering temperature and voltage [J]. Chinese Journal of Power Sources, 2018, 42(1): 90-92, 96. (in Chinese)

[8] 信月, 杨中平, 林飞, 等. 基于参数反馈的城轨交通超级电容健康状态估算[J]. 电工技术学报, 2019, 34(S1): 396-404.
Xin Yue, Yang Zhongping, Lin Fei, et al. Research on state of health estimation of supercapacitor in urban rail transit based on parameter feedback [J]. Transactions of China Electrotechnical Society, 2019, 34(S1): 396-404. (in Chinese)

[9] Soualhi A, Sari A, Razik H, et al. Supercapacitors ageing prediction by neural networks [C]// IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society. Vienna, Austria, 2013: 6812-6818.

[10] Zhou Yanting, Wang Yanan, Wang Kai, et al. Hybrid genetic algorithm method for efficient and robust evaluation of remaining useful life of supercapacitors [J]. Applied Energy, 2020, 260: 114169.

[11] 时洪雷. 超级电容器参数老化趋势预测[D]. 大连: 大连理工大学, 2017.
Shi Honglei. Parameters aging trend prediction of supercapacitor [D]. Dalian: Dalian University of Technology, 2017. (in Chinese)

[12] Cortes C, Vapnik V. Support-vector networks [J]. Machine Learning, 1995, 20(3): 273-297.

[13] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.

[14] 蒋勇, 李宏, 焦永昌. 改进 NSGA-Ⅱ终止判断准则[J]. 计算机仿真, 2009, 26(2): 196-200.
Jiang Yong, Li Hong, Jiao Yongchang. A new termination criterion of NSGA-Ⅱ [J]. Computer Simulation, 2009, 26(2): 196-200. (in Chinese)

[15] 宋健正, 刘洋, 崔来熙, 等. 基于 IGWO-MKELM 的锂离子电池剩余使用寿命预测[J]. 电源学报, 2023, 21(1): 168-176.
Song Jianzheng, Liu Yang, Cui Laixi, et al. Remaining useful life prediction of lithium-ion batteries based on improved grey wolf optimization multiple kernel extreme learning machine [J]. Journal of Power Supply, 2023, 21(1): 168-176. (in Chinese)



刘晓明

**作者简介：**

刘晓明(1968— )，女，博士，教授。研究方向：高压电器和智能电器。E-mail：liuxiaoming@hebut.edu.cn。

任宇朋(1998— )，男，中国电源学会会员，通信作者，硕士研究生。研究方向：现代电器设计与应用。E-mail：1392203050@qq.com。

陈海(1968— )，男，硕士，工程师。研究方向：高压电器和智能电器。E-mail：chehai@hebut.edu.cn。

冯大伟(1992— )，男，博士，讲师。研究方向：高电压与绝缘技术。E-mail：josaturday@hebut.edu.cn。

田俊(1994— )，男，硕士研究生。研究方向：现代电器设计与应用。E-mail：949204816@qq.com

(责任编辑：郭凯凯)