

朱君祺, 王贤琳, 张豪, 等. 基于 ANPSO-MKRVM 的锂电池寿命预测[J]. 智能计算机与应用, 2025, 15(7): 175-181. DOI: 10.20169/j.issn.2095-2163.24100905

基于 ANPSO-MKRVM 的锂电池寿命预测

朱君祺, 王贤琳, 张豪, 刘恺

(武汉科技大学 机械自动化学院, 武汉 430081)

摘要: 锂电池具有诸多优点, 广泛应用于民用和军工领域, 随着其应用越加广泛和产业快速发展, 电池报废处理亟待解决, 研究其剩余使用寿命, 提前预知失效时间显得尤为重要。相关向量机(RVM)被广泛应用于寿命预测, 核函数作为 RVM 关键部分, 对预测结果有较大影响。传统粒子群优化 RVM 模型的预测性能有限, 本文提出了一种自适应邻域粒子群算法(ANPSO), 用于优化多核相关向量机模型(MKRVM), 提高模型的预测精度, 将该模型应用于锂离子电池的循环剩余寿命预测。采用美国 NASA 电池退化数据集对所构建的 ANPSO-MKRVM 模型进行仿真实验验证, 结果表明: 本文构建的模型的均方根误差和平均绝对误差都小于传统粒子群优化多核相关向量机(PSO-MKRVM)模型和传统 RVM 模型。

关键词: 锂电池; 剩余寿命预测; 多核相关向量机; 自适应邻域粒子群

中图分类号: TP202+.1

文献标志码: A

文章编号: 2095-2163(2025)07-0175-07

Lifetime prediction of lithium batteries based on ANPSO-MKRVM

ZHU Junqi, WANG Xianlin, ZHANG Hao, LIU Kai

(College of Machinery and Automation, Wuhan University of Science and Technology, Wuhan 430081, China)

Abstract: Lithium battery has many advantages, is widely used in civil and military fields, with its increasing application and rapid development of the industry, battery scrapping treatment urgently needs to be solved, research its remaining service life, predict the failure time in advance is particularly important. Correlation vector machine (RVM) is widely used in life prediction. Kernel function, as a key part of RVM, has great influence on the prediction result. In this paper, an adaptive neighborhood particle swarm optimization (ANPSO) algorithm is proposed to improve the prediction accuracy of the multi-core correlation vector machine (MKRVM) model by optimizing the predictive performance of the traditional particle swarm optimization RVM model, and the model is applied to the prediction of the cycle remaining life of pre-lithium-ion batteries. The ANPSO-MKRVM model was verified by using the NASA battery degradation dataset. The results show that the root-mean-square error and mean absolute error of the proposed model are smaller than the traditional PSO-MKRVM model and the traditional RVM model.

Key words: lithium battery; remaining useful life prediction; multi kernel relevance vector machine; adaptive neighborhood particle swarm optimization

0 引言

以汽油等化石燃料为能源的传统汽车, 面临诸多问题, 如排放物对环境的影响以及对人身体的危害。全球资源越来越匮乏, 环境污染严重, 国家在汽车长远发展方面制定了一系列的战略举措, 以促进传统汽车向新能源汽车转型。锂电池具有较多优点, 如能量密度高、寿命长等, 广泛应用于新能源汽车^[1]。国家对新能源的大力支持以及油价上涨等

原因, 越来越多的人选择新能源汽车。据公安部统计, 截至 2024 年底, 全年全国民用汽车产量 3 155.9 万辆(包括新能源汽车 1 316 万辆), 比上年末增加 4.8%(新能源汽车增长 38.7%)^[2]。这又面临一个新问题, 报废的电池也会越来越多。在使用新能源汽车过程中, 电池内部结构不断变化, 锂电池的剩余使用寿命(Remining Useful Life, RUL)预测非常重要^[3]。

目前锂电池寿命预测主要有 3 大类方法: 基于

作者简介: 朱君祺(1999—), 男, 硕士研究生, 主要研究方向: 绿色制造, 信息技术应用; 张豪(1998—), 男, 硕士研究生, 主要研究方向: 质量管理与可靠性, 信息技术应用; 刘恺(2001—), 男, 硕士研究生, 主要研究方向: 绿色制造。

通信作者: 王贤琳(1969—), 女, 博士, 教授, 主要研究方向: 绿色制造, 质量工程。Email: wangxianlin@wust.edu.cn。

收稿日期: 2023-11-07

哈尔滨工业大学主办 ◆ 科技创见与应用

模型、基于数据驱动和基于融合^[4]。基于数据驱动是目前主要的方法,数据驱动方法不依赖于电池物理模型的精度,通常通过提取退化数据的典型特征来建立回归模型,预测剩余寿命^[5]。刘琼等^[6]采用梯度提升决策树算法建立 RUL 预测模型,利用网格搜索法进行参数优化,取得了较好的预测精度;徐佳宁^[7]、郑青根^[8]等分别提出了改进狮蚁优化算法和改进灰狼优化算法来优化支持向量机 (Support Vector Machine, SVM),对锂电池进行 RUL 预测,该类方法取得了较好的预测效果;Dai Y 等^[9]以动车组电池为对象,提出基于线性 Wiener 过程的寿命预测方法,二元线性 Wiener 模型比一元有更高的精度;胡杰等^[10]提取车辆真实的运行参数和环境参数,建立灰色预测和长短时记忆神经网络预测模型,并通过 Stacking 模型融合进一步降低预测误差;周雅夫等^[11]将传统的经验指数模型和改进后的多项式回归模型进行融合重组,拟合能力更优,在役电池和退役电池上都具有高精度预测结果,在梯次利用行业具有一定适用性。由于长期预测方法的稳定性较弱,Fan 等^[12]利用贝叶斯算法优化核函数,建立了改进的 RVM (Relevance Vector Machine) 回归模型,改进后的模型具有较好的短期预测性能和长期预测稳定性;焦自权等^[13]用贝叶斯理论对历史样本进行状态跟踪,用状态跟踪训练优化后最新量测信息取代旧信息,提出基于 MCMC (Markov Chain Monte Carlo) 方法结合改进粒子滤波预测模型,改进的模型具有较强的稳定鲁棒性、泛化适应性和通用有效性;余佩雯等^[14]采用分段迭代的预测方法,利用 RVM 回归模型将长期预测过程分为多个短期过程,对每次预测结果进行时间关联性分析。相比于传统单核相关向量机模型,多核相关向量机模型 (Multi-Kernel Relevance Vector Machine, MKRVM) 具有更多优势,多核核函数的参数选取对预测精度有重大影响,许多学者提出了其他优化方法对核参数进行优化,比如刘月峰等^[15]提出了 MKRVM 模型,利用果蝇算法优化多核线性参数,采用两种不同的数据集,对比单核与多核两种方法的预测结果,多核 RVM 模型精度更高。

RVM 算法模型基于贝叶斯框架,相比于支持向量机,RVM 泛化能力较好,最重要的是 RVM 不用满足 Mercer 定理。传统粒子群算法对于较为复杂的目标函数,容易陷入局部最优解,如何获得较优的核参数是本文研究的重点,针对上述问题,本文提出一种自适应邻域粒子群优化算法 (Adaptive

Neighborhood Particle Swarm Optimization, ANPSO),对多核 RVM 模型中的核参数进行优化,自动确定最优的核参数,并与传统 PSO-MKRVM 模型以及传统 RVM 模型比较,实验验证本文提出的预测模型具有较好的预测精度,一定程度上避免寻优过程陷入局部最优解。

1 MKRVM 模型

1.1 基于相空间重构的数据预处理

锂电池容量退化可以看作是混沌时间序列,混沌时间序列是基于相空间的,混沌时间序列关键处理步骤是相空间重构^[16]。根据 Takens 定理,锂离子电池一维时间序列为 $\{x(i), i = 1, 2, \cdots, N\}$,若存在一个嵌入维数 m ,使得 $m \geq 2d + 1$, d 为混沌吸引子所在的相空间的拓扑维数时,利用时间延迟 τ 将电池一维时间序列映射为 m 维时间序列, $Y(i)$ 为第 i 个相点,表达式如下:

$$Y(i) = \{x(i), x(i + \tau), x(i + \tau), \cdots, x[i + (m - 1)\tau]\}$$

(1)

其中, m 为嵌入维数; τ 为时间延迟; $i = 1, 2, \cdots, M$, M 满足 $M = N - (M - 1)\tau$ 。

相空间重构的关键是确定嵌入维数和时间延迟。嵌入维数过大会导致漏掉原始数据之间的内部关系;过小又会造成拟合效果不佳,以致无法判断内部关系。当原始数据有限时,时间延迟的大小才会对重构结果有影响,过大会导致模型失真,准确性下降;过小又会使坐标交叠过强。相空间重构后的输入和输出见表 1。

表 1 相空间重构后的输入与输出

Table 1 Input and output after phase space reconstruction

数据集编号	输入 $x(i)$	输出 $Y(i)$
1	$x(1), x(2), \cdots, x(m)$	$x(m + \tau)$
2	$x(2), x(3), \cdots, x(m + 1)$	$x(m + 1 + \tau)$
$\vdots$	$\vdots$	$\vdots$
$n - m - \tau + 1$	$x(n - m - \tau + 1),$ $x(n - m - \tau + 2), \cdots, x(n - \tau)$	$x(n)$

对于嵌入维数和时间延迟的确定,参数取值对重构结果的影响,张洋^[17]以电池容量退化为基础,构造相空间,并经过仿真实验得出时间延迟为 2,嵌入维数为 5 时效果最好的结论。本文借鉴研究经验,取时间延迟 $\tau = 2$,嵌入维数 $m = 5$ 。

1.2 多核相关向量机核函数的选择

Tipping^[18]在 2000 年提出贝叶斯概率模型 RVM,具有较好的泛化能力和稀疏性,是一种监督

学习方法,监督的样本由输入矢量和目标值组成。在SVM基础上,RVM将目标值加上了噪声影响,两者关系如下:

$$t = y(x, w) + \varepsilon_n = \left(\sum_{i=1}^M w_i K(x, x_i) + w_0 \right) + \varepsilon_n \quad (2)$$

其中, $K(x, x_i)$ 为核函数; $\{w_n\}$ 为对应权值; ε_n 为独立同分布的高斯噪声,且 $\varepsilon_n \sim N(0, \sigma^2)$ 。

由贝叶斯推理可知 $p(t|x)$ 满足 $N(t|y(x, w), \sigma^2)$ 分布。假设 $\{t_n\}_{n=1}^N$ 为独立随机变量,似然函数如下式:

$$p(t|w, \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{1}{2\sigma^2} \|t - \Phi w\|^2\right\} \quad (3)$$

其中, $t = (t_1, t_2, \dots, t_N)$, $w = (w_0, w_1, \dots, w_N)$, $\Phi = [\phi_1, \phi_2, \dots, \phi_N]$, $\phi_n = [1, K(x_n, x_1), \dots, K(x_n, x_N)]$ 。

RVM有着与SVM一样的函数形式,即核函数将低维时间序列映射到高维,核函数不同对预测结果也有一定的影响。对于传统的单个核函数,其鲁棒性较差。目前多个核函数的线性组合应用更广泛,能提高RVM模型的泛化能力。Yang^[19]提出利用多核RVM,显著提高模型的泛化能力。

核函数分为全局核函数和局部核函数两类。高斯核函数是局部性较强的核函数,多项式核函数则为全局性较强的核函数,这两种最典型核函数,应用最广泛,两种核函数表达式如下:

$$K_{RBF}(x, z) = \exp(-\gamma \cdot \|x - z\|^2) \quad (4)$$

$$K_{poly}(x, z) = (x \cdot z + 1)^2 \quad (5)$$

其中, γ 为核参数。

为了保留两类核函数的优势,采用线性组合形式:

$$K(x, z) = \lambda K_{RBF}(x, z) + (1 - \lambda) K_{poly}(x, z) \quad (6)$$

其中, λ 为线性组合参数,取值范围为 $[0, 1]$ 。

1.3 自适应邻域基本粒子群算法

1995年,美国学者Kennedy和Eberhart共同提出了粒子群算法,对鸟类活动建模,主要思想是在鸟群中,将个体和群体之间信息共享,从而在不断运动中获得目标可行解。

算法初始化为一群粒子,不断迭代更新速度和位置,找到最优适应度,即最优解。粒子群算法的迭代更新公式如下:

$$v_i^d = wv_i^{d-1} + c_1 r_1 (p_{best}^d - x_i^d) + c_2 r_2 (g_{best}^d - x_i^d) \quad (7)$$

其中, v_i^d, x_i^d 分别为第 d 次迭代时第 i 个粒子的速度和所在的位置; w 为速度的惯性权重; c_1, c_2 分别为粒子的个体学习因子和粒子的社会学习因子;

r_1, r_2 为介于 $[0, 1]$ 的随机数; p_{best}^d, g_{best}^d 分别为到第 i 次迭代为止,第 i 个粒子经过的最好位置和所有粒子经过的最好位置。

传统粒子群简单、参数较少,但其对于复杂的目标函数,容易陷入局部最优解^[20]。为此,本文提出一种自适应邻域粒子群算法,以提高粒子群算法的搜索能力和效率。在搜索过程中将周围部分粒子视为邻域粒子,使得粒子群可以被分割成多个不同的子群体,有利于在多个区域搜索,找到适应度最小的位置。

自适应邻域粒子群算法具体步骤如下:

Step 1 预设参数的选取。基于目前已有研究现状,选取粒子群算法各个参数。

(1) 粒子个数

默认设置为: $\min\{100, 10 \times nvars\}$, $nvars$ 是变量个数。

(2) 惯性权重

默认设置的范围为: $[0.1, 1.1]$, 在迭代过程中惯性权重会采取自适应措施,随着迭代过程不断调整。

(3) 个体学习因子与社会学习因子

默认设置均为 1.49。

(4) 邻域内粒子的比例

默认设置为 0.25, 由于采取的是邻域模式,因此定义了一个“邻域最少粒子数目”: $\max\{2, (\text{粒子数目} \times \text{邻域内粒子的比例}) \text{的整数部分}\}$, 在迭代开始后,每个粒子会有一个邻域,初始时邻域内的粒子个数记为 Q , 等于“邻域最少粒子数目”,后续邻域内的粒子个数 Q 会自适应调整。

Step 2 变量初始化和适应度的计算。

(1) 速度初始化: 与基本粒子群类似,但最大速度为上界与下界的差额:

$$\begin{cases} v_{\max} = ub - lb; \\ v = -v_{\max} + 2 \times v_{\max} \times \text{rand}(n, nvars) \end{cases} \quad (8)$$

其中, $v_{\max}$ 是最大速度限制, v 为生成粒子的初始速度。

(2) 位置初始化

将每个粒子的位置均匀分布在上下界约束内。

(3) 计算每个粒子的适应度

适应度仍设置为本文要优化的目标函数,由于该函数求解的是最小值问题,因此最优解应为适应度最小即目标函数越小的解。

(4) 初始化个体最优位置

个体最优位置就是本文初始化得到的位置。

(5) 初始化所有粒子的最优位置

只需要找到适应度最低的那个粒子,并记其位

置,为所有粒子的最优位置。

Step 3 更新粒子的速度和位置。在每次迭代中,分别更新每一个粒子的信息,例如:对于现在要更新的粒子 i , 要进行以下几个操作:

(1) 随机生成粒子 i 的邻域,邻域内一共 Q 个粒子(包含粒子 i 本身),并找到这 Q 个粒子中位置最佳的那个粒子,此时其目标函数值最小,记其位置为 $lbest$;

(2) 更新粒子 i 的速度:

$$v_i^d = wv_i^{d-1} + c_1r_1(p_{best_i}^d - x_i^d) + c_2r_2(g_{best}^d - x_i^d) \quad (9)$$

速度公式(9)和基本粒子群算法最大的不同在于公式(9)中群体信息共享部分是邻域内的最优粒子,而不是整个群体;

(3) 更新粒子 i 的位置:

$$x_i^{d+1} = x_i^d + v_i^d \quad (10)$$

(4) 修正位置和速度:如果粒子 i 的位置超过了约束,就将其位置修改到边界处;若该粒子的位置在边界处,还需查看其速度是否超过最大速度,若超过,则将该速度变为 0。如果是多元函数的话可能只有某个分量超过了约束,需要针对这个分量即可。

(5) 计算粒子 i 的适应度,如果小于其历史最佳的适应度,就更新粒子 i 的历史最佳位置为现在的位置;另外还需要判断粒子 i 的适应度是否要小于所有粒子迄今为止找到的最小适应度,如果小的话需要更新所有的粒子的最佳位置为粒子 i 的位置。

假设在第 d 次迭代过程中,所有的粒子信息都已更新好,在开始下一次的迭代之前,还需更新模型中的参数,体现了自适应过程。

记此时所有粒子的最小适应度为 a , 上一次迭代完成后所有粒子的最小适应度为 b 。比较 a 和 b 的相对大小,如果 $a < b$, 则记 $flag = 1$; 否则记 $flag = 0$ 。

如果 $flag = 0$, 进行以下操作:

(1) 更新 $c = c + 1$, c 表示“停滞次数计数器”,在开始迭代前就初始为 0;

(2) 更新邻域内的粒子个数 Q , 邻域最少粒子数目 $\min NeighborhoodSize$ 、粒子的总数 $SwarmSize$, 即 $Q = \min\{Q + \min NeighborhoodSize, SwarmSize\}$ 。

如果 $flag = 1$, 进行以下操作:

(1) 更新 $Q = \min NeighborhoodSize$;

(2) 更新 $c = \max\{c - 1, 0\}$;

(3) 判断 c 的大小,如果 $c < 2$, 则更新 $w = 2 \times w$; 如果 $c > 5$, 则更新 $w = w/2$; w 是惯性权重,如果计算的结果超过了惯性权重的上界或低于下界都需

要将其调整到边界处。

自适应体现在:如果适应度开始停滞时,粒子群搜索会从邻域模式向全局模式转换,一旦适应度开始下降,则又恢复到邻域模式,以免陷入局部最优。当适应度的停滞次数足够大时,惯性系数开始逐渐变小,从而利于局部搜索。ANPSO 优化 MKRVM 模型流程如图 1 所示。




图1 ANPSO 算法优化 MKRVM 模型流程

Fig. 1 Flow of the MKRVM model optimized by ANPSO

2 仿真实验与分析

2.1 实验数据

本文所采用的仿真实验数据选用的是美国宇航局 PCoE 研究中心 (National Aeronautics and Space Administration Prognostics Center of Excellence, NASA PCoE) 公开的锂离子电池老化试验数据集, 选取同一批次的电池 (即 B05、B06、B07 和 B18) 对模型进行验证, 性能退化的每个实验周期如下:

(1) 充电阶段: 在电池电压达到 4.2 V 之前, 以 1.5 A 恒流充电, 随后变为恒压充电, 当电流下降到 20 mA 时结束充电;

(2) 放电阶段: 以恒流 2.0 A 持续放电, 直到 4 组电池电压分别降为 2.7、2.5、2.2 和 2.5 V;

(3) 阻抗测量: 电化学阻抗谱法 (Electrochemical Impedance Spectroscopy, EIS) 采集电池内阻。

目前对于锂电池失效容量, 认为达到额定容量的 70% 左右时即失效。4 组电池容量随充放电周期退化曲线如图 2 所示, 可见随着充电放电循环, 4 组电池容量不同程度的衰减, 其中有部分波动, 称为容量再生现象。




图 2 NASA 电池容量退化曲线

Fig. 2 NASA Battery capacity degradation curve

2.2 实验分析

本文使用数据集对所提出的自适应邻域粒子群优化多核相关向量机模型预测效果进行验证,并与传统粒子群优化多核相关向量机模型和传统相关向量机模型进行对比分析。

采用 3 种评价准则,分别为均方根误差 (Root Mean Square Error, $RMSE$)、拟合优度 ($R - squared$) 和平均绝对误差 (Mean Absolute Error, MAE), 3 个评价准则定义如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x}(i))^2} \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x(i) - \hat{x}(i))^2}{\sum_{i=1}^n (x(i) - \bar{x}(i))^2} \quad (12)$$





图 3 ANPSO-MKRVM 预测结果

Fig. 3 Predicted results using ANPSO-MKRVM

$$MAE = \frac{1}{n} \sum_{i=1}^n |x(i) - \bar{x}(i)| \quad (13)$$

其中, n 表示循环预测电池容量的周期数; $x(i)$ 表示第 i 周期电池容量的实际值; $\bar{x}(i)$ 表示预测值。

仿真实验步骤:

Step 1 将 B5、B6 和 B7 3 组电池前 84 个周期数据和 B18 电池前 66 个周期数据进行相空间重构,将重构后的数据集作为模型输入,剩下数据集作为测试集,测试集不需要进行相空间重构;

Step 2 粒子群优化的目标函数为电池预测均方根误差,模型开始训练前,生成随机的邻域粒子,然后根据邻域内的最优粒子,不断更新粒子速度和位置,在这个过程中,如果粒子速度和位置超过约束,就对其进行修正,重新计算粒子适应度,直到找到迄今为止位置最佳的粒子,在寻优过程中,粒子群的惯性会自适应的变化;

Step 3 得到模型的输出,即电池数据集的预测容量及 4 组电池的误差。

以 4 组电池数据集前 50% 循环周期数据作为训练集,后 50% 循环周期数据作为测试集。ANPSO-MKRVM 模型的预测结果如图 3 所示,可见 4 组预测曲线与真实容量较为贴近。以 B05 为例,对比 3 种方法的预测结果如图 4 所示,可见 RVM 方法在前 40 周期拟合效果较差,ANPSO-MKRVM 方法在周期 30~50 之间拟合效果优于 PSO-MKRVM。




图 4 PSO-MKRVM 和 RVM 预测结果

Fig. 4 Predicted results using PSO-MKRVM and RVM

3 种方法的预测误差,见表 2。由表 2 可知:对于 B5 号电池,ANPSO-MKRVM 方法所得到的 *RMSE* 和 *MAE* 值均比其他两种方法小;另外 3 组电

池,ANPSO-MKRVM 方法所得到的 *RMSE* 和 *MAE* 值也均小于其他两种方法,说明 ANPSO-MKRVM 方法能够获得更小的预测误差。

表 2 3 种方法的预测误差

Table 2 Prediction error by three methods

型号	ANPSO-MKRVM			PSO-MKRVM			RVM		
	<i>RMSE</i>	<i>R</i> ²	<i>MAE</i>	<i>RMSE</i>	<i>R</i> ²	<i>MAE</i>	<i>RMSE</i>	<i>R</i> ²	<i>MAE</i>
B5	0.023 2	0.937 9	0.018 8	0.026 8	0.919 8	0.022 1	0.030 5	0.907 2	0.023 4
B6	0.028 2	0.968 1	0.021 1	0.032 4	0.956 9	0.025 0	0.047 7	0.914 0	0.039 4
B7	0.018 9	0.954 1	0.014 9	0.020 5	0.946 4	0.015 9	0.020 8	0.948 1	0.015 8
B18	0.021 2	0.926 5	0.016 9	0.021 5	0.924 4	0.017 2	0.025 9	0.889 1	0.018 6

3 结束语

本文构建的 ANPSO-MKRVM 模型,利用 ANPSO 优化两个核函数的线性组合系数以及高斯核参数,解决了单核 RVM 模型预测能力较低的问题以及传统粒子群算法的局限性。使用 ANPSO 优化组合核函数 RVM 模型的预测精度得到了提高,使用 ANPSO-MKRVM 方法的 *RMSE* 平均值为 2.29%,比传统的 PSO-MKRVM 模型和 RVM 模型分别降低了 0.24% 和 0.83%;*MAE* 平均值为 1.83%,分别降低了 0.18% 和 0.6%。

参考文献

[1] 马建,刘晓东,陈轶嵩,等. 中国新能源汽车产业与技术发展现状 & 对策[J]. 中国公路学报,2018,31(8):1-19.

[2] 国家统计局. 中华人民共和国 2024 年国民经济和社会发展统计公报 [N]. 人民日报,2025-03-01(005). DOI:10.28655/

n.cnki.nrmrb.2025.002534.

[3] CANO Z P, BANHAM D, YE S, et al. Batteries and fuel cells for emerging electric vehicle markets[J]. Nature Energy, 2018, 3(4):279-289.

[4] 蔡艳平,陈万,苏延召,等. 锂离子电池剩余寿命预测方法综述[J]. 电源技术,2021,45(5):678-682.

[5] LI X, MA Y, ZHU J J. An online dual filters RUL prediction method of lithium-ion battery based on unscented particle filter and least squares support vector machine[J]. Measurement, 2021, 184:109935.

[6] 刘琼,张豹. 基于 GBDT 算法的锂电池剩余使用寿命预测[J]. 电子测量与仪器学报,2022,36(10):166-172.

[7] 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.

[8] 郑青根,杨祥国,刘冬,等. 改进灰狼优化最小二乘支持向量机的锂电池剩余寿命预测[J]. 重庆大学学报,2023,46(11):78-89.

[9] DAI Y, CHENG S, GAN Q J, et al. Life prediction of Ni-Cd battery based on linear Wiener process [J]. Journal of Central South University,2021,28(9):2919-2930.

[10] 胡杰,何陈,朱雪玲,等. 基于实车数据的电动汽车电池剩余

使用寿命预测 [J]. 交通运输系统工程与信息, 2022, 22(1): 292–300.

[11]周雅夫, 刘邵勋, 孙宵宵, 等. 车用动力电池全生命周期寿命预测方法[J]. 哈尔滨工业大学学报, 2022, 54(6): 37–44.

[12]FAN Y, QIU J, WANG S, et al. Incremental capacity curve health-indicator extraction based on gaussian filter and improved relevance vector machine for lithiumion battery remaining useful life estimation[J]. Metals, 2022, 12(8): 1331.

[13]焦自权, 范兴明, 张鑫, 等. 基于改进粒子滤波算法的锂离子电池状态跟踪与剩余使用寿命预测方法[J]. 电工技术学报, 2020, 35(18): 3979–3993.

[14]余佩雯, 郁亚娟, 常泽宇, 等. 相关向量机预测锂离子电池剩余有效寿命[J]. 电气技术, 2023, 24(2): 1–5.

[15]刘月峰, 赵光权, 彭喜元. 多核相关向量机优化模型的锂电池剩余寿命预测方法[J]. 电子学报, 2019, 47(6): 1285–1292.

[16]HOU Y, LI D, ZHANG D, et al. An improved phase space reconstruction method-based hybrid model for chaotic traffic flow prediction[J]. Discrete Dynamics in Nature and Society, 2022, 2022(1): 5604674.

[17]张洋, 陈浩, 郭波, 等. 锂离子电池剩余寿命在线预测[J]. 机械科学与技术, 2016, 35(8): 1286–1290.

[18]TIPPING M E. Sparse Bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research, 2001, 1(1): 211–244.

[19]YANG Y, WEN J, LIANG J, et al. Remaining useful life prediction for lithium-ion batteries based on the partial voltage and temperature[J]. Sustainability, 2023, 15(2): 1602.

[20]陈建杰, 刘衍民, 骆怡. 双子群自适应变异多目标粒子群算法[J]. 遵义师范学院学报, 2024, 26(6): 86–93.