

DOI: 10.13382/j.jemi.B2104148

基于 IALO-SVR 的锂电池健康状态预测*

李强龙¹ 孙建瑞² 赵坤² 王凯¹

(1. 青岛大学电气工程学院 青岛 266071; 2. 山东广域科技 东营 257000)

摘要:健康状态(SOH)预测作为锂离子电池管理系统(BMS)的关键功能之一,对于保证电池安全可靠运行、降低电池系统维护成本具有重要意义。为了提高锂电池SOH预测精度,提出一种基于改进的蚁狮优化算法和支持向量回归(IALO-SVR)的SOH预测方法,首先从电池充电数据中提取与电池容量相关的特征因子并进行相关性分析,选取相关度高的3个作为模型特征输入,再导入样本数据,通过改进的蚁狮优化算法(IALO)对SVR模型的关键参数进行寻优,建立最终预测模型。在NASA公开数据集上与现有的遗传算法-支持向量回归(GA-SVR)和改进粒子群算法-支持向量回归(IPSO-SVR)进行对比实验,结果表明IALO-SVR方法拥有更高的预测精度与拟合度,预测误差基本保持在1%以内,验证了预测方法的可行性。

关键词: 锂离子电池;健康状态;改进的蚁狮优化算法;支持向量回归

中图分类号: TM912 文献标识码: A 国家标准学科分类代码: 120.30

Prediction for the state of health of lithium-ion batteries based on IALO-SVR

Li Qianglong¹ Sun Jianrui² Zhao Kun² Wang Kai¹

(1. College of Electrical Engineering, Qingdao University, Qingdao 266071, China;

2. Shandong Guangyu Technology, Dongying 257000, China)

Abstract: State of health (SOH) prediction, as one of the key functions of lithium ion battery management system (BMS), is of great significance to ensure the safe and reliable operation of batteries and reduce the maintenance cost of battery system. In order to improve the prediction accuracy of lithium battery SOH, a SOH prediction method based on improved ant-lion optimization algorithm and support vector regression (IALO-SVR) is proposed. Firstly, the characteristic factors related to battery capacity are extracted from the battery charging data, and the correlation analysis is carried out. The three features with high correlation are selected as the model feature inputs, and then the sample data is imported. The key parameters of SVR model are optimized by the IALO algorithm, and the final prediction model is established. Compared with the existing GA-SVR and IPSO-SVR, the results show that IALO-SVR method NASA has higher prediction accuracy and fitting degree, and the prediction error is basically kept within 1%, which verifies the feasibility of the prediction method.

Keywords: lithium-ion battery; state of health; improved antlion optimization algorithm; support vector regression

0 引言

随着新能源应用的兴起,锂离子电池凭借其高能量密度、高电势、良好的低温性能、低自放电率和长寿命的特点,已被广泛用于电动汽车上^[1]。然而随着锂电池使

用次数的增加,电池会出现老化问题,如果不能及时发现并处理故障电池,可能会损害电池储能系统,影响电动汽车的安全性与稳定性。因此,提升锂离子电池健康状态(SOH)的预测精度对提高电池管理系统的安全性和可靠性具有重要的现实意义,当下,锂电池SOH的预测已经成为电池领域一个热门研究方向^[2]。

收稿日期: 2021-04-08 Received Date: 2021-04-08

* 基金项目: 山东省自然科学基金(ZR2020QE212)、山东省自然科学基金重点项目(ZR2020KF020)、青岛大学2020年创新型教学实验室研究项目(CXSYYB202003)资助

近年来,关于锂电池 SOH 预测方法的研究越来越多,主流 SOH 预测方法主要可分为自适应估计方法、基于退化模型的方法和基于数据驱动的方法^[3]3类。自适应估计方法主要包括基于卡尔曼滤波(Kalman filter, KF)的方法和基于粒子滤波(particle filter, PF)的方法,是估计锂电池 SOH 的有效方法。程泽等^[4]提出了一种基于自适应平方根无迹卡尔曼滤波算法来同时估计 SOC 和 SOH,但是这种方法需要大量计算,且对数据精度要求较高,存在一定局限。基于退化模型的方法是通过对比电池电化学机理进行分析,建立电池模型并考虑内部变量(如电解质浓度和扩散系数)和外部影响因素(如电压、电流、温度和荷电状态)来实现 SOH 的估计。然而,退化模型方法原理复杂且容易受外部因素影响,难以建立稳定的模型,局限性较大^[5]。相比而言,数据驱动方法无需了解电池的复杂内部机理和考虑电化学反应,只需通过检测电池外部参数并从中提取与 SOH 变化高度相关的特征因子,将其作为训练数据构建预测模型,从而实现对比锂电池 SOH 的实时预测。常用的数据驱动方法有高斯过程回归(gaussian process regression, GPR)、人工神经网络(artificial neural networks, ANN)、支持向量回归(support vector regression, SVR)等。相比于其他数据驱动方法,SVR 拥有完善的理论基础与强大的抗泛化能力,在处理小样本、非线性拟合问题上具有独特优势,已成为 SOH 预测的热门方法之一。Qin 等^[6]提出一种基于改进粒子群优化支持向量回归(IPSO-SVR)算法的 SOH 预测方法;Yang 等^[7]提出一种基于最小二乘支持向量回归(LSSVR)模型的 SOH 预测方法;Ma 等^[8]提出一种基于多视角特征融合的支持向量回归集成方法(MVFF-ESVR)来估算 SOH;Feng 等^[9]提出一种基于增量容量分析支持向量回归(ICA-SVR)的锂电池 SOH 实时预测方法。对于数据驱动方法,特征因子的选取直接影响数据驱动方法预测的准确性^[10],SVR 模型的惩罚因子和核函数参数决定了预测模型的性能,因此预测模型中特征因子的选取与模型参数的选取对 SOH 预测准确度有较大影响,如何选择最优参数仍是需要解决的问题。

为了有效解决 SVR 预测模型的参数选择问题,本文提出一种基于改进蚁狮算法和支持向量回归(improved ant lion optimizer-support vector regression, IALO-SVR)的 SOH 预测方法,该方法能高度拟合 SOH 衰退曲线,有效提升 SOH 的预测精度。首先将与电池容量衰减和功率衰减高度相关的恒流充电持续时间 TC、恒压充电持续时间 TV、充放电循环次数 CN 选取为预测模型的特征输入,通过 IALO 算法对 SVR 模型关键参数进行全局寻优,用样本集训练后得到最终预测模型。基于 NASA 电池数据集,应用本文提出的 IALO-SVR 模型与其他 SVR 模型对比分析,实验结果证明,IALO-SVR 在提升预测精度的

同时,保持了较高的稳定性,具有广阔的应用前景。

1 基本算法

1.1 SVR 模型

SVR 模型是基于支持向量机(SVM)模型在函数回归领域的拓展,由 Cortes 等^[11]在 SVM 分类的基础上引入了 ε 不敏感损失函数,在处理小样本、非线性拟合问题方面具有巨大优势,目前被广泛应用于机器学习。给定样本集 $S = \{(x_1, y_1), \dots, (x_N, y_N) \mid x_i \in \mathbf{R}^n, y_i \in \mathbf{R}\}$ (x_i 为第 i 个样本的特征向量, y_i 为第 i 个样本的回归值, N 为样本个数, n 是输入向量的维数),SVR 的核心思想是通过非线性变换将原始样本集从原始特征空间映射到高维特征空间,然后在高维特征空间建立一个线性模型对样本集进行回归拟合。

SVR 回归函数定义如下:

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

式中: f 函数为输出; \mathbf{w} 为权重向量; $\Phi(\mathbf{x})$ 为高维非线性映射函数; b 为偏差值。 \mathbf{w} 和 b 参数可通过建立如下目标函数来求解:

$$\min R(F) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N |f(\mathbf{x}_i) - y_i|_{\varepsilon} \quad (2)$$

式中: C 为惩罚因子; N 为训练样本个数; $f(\mathbf{x}_i)$ 为第 i 个样本的预测值; y_i 为第 i 个样本的真实值; ε 为回归允许的最大误差; $|f(\mathbf{x}_i) - y_i|_{\varepsilon}$ 为 ε 不敏感损失函数。

$$|f(\mathbf{x}) - y|_{\varepsilon} = \max\{0, |f(\mathbf{x}) - y| - \varepsilon\} \quad (3)$$

引入松弛变量 ξ 和 ξ^* 后,目标函数由式(2)转变为以下约束形式:

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (4)$$

式中: ξ_i 和 ξ_i^* 为第 i 个训练样本的松弛变量, ξ_i 、 ξ_i^* 、 $f(\mathbf{x}_i)$ 、 ε 之间满足式(5)约束条件。

$$\text{s. t.} = \begin{cases} y_i - f(\mathbf{x}_i) \leq \varepsilon + \xi_i \\ f(\mathbf{x}_i) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (5)$$

可以通过添加拉格朗日算子及核函数将式(4)转化为求解对偶问题,得到回归函数:

$$f(\mathbf{x}) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}_j) + b \quad (6)$$

式中: α_i 和 α_i^* 为拉格朗日算子, \mathbf{x}_i 、 \mathbf{x}_j 分别为训练样本和测试样本中的输入向量,其中 $K(\mathbf{x}_i, \mathbf{x}_j)$ 为核函数,在求解非线性问题时通常采用径向基核函数(RBF)作为核函数,其定义如下:

$$K_{RBF}(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}_i - \mathbf{x}_j\|^2\right) \quad (7)$$

式中: σ 为 RBF 核函数的宽度。

1.2 蚁狮优化算法

蚁狮优化算法 (ant lion optimizer, ALO) 是 Mirjalili^[12] 于 2015 年受自然界中蚁狮捕食蚂蚁过程启发而提出的新型智能优化算法, 相比于传统算法表现出强大的探索与开发性能, 能很大程度避免陷入局部寻优。

ALO 算法具体优化步骤如下:

1) 蚂蚁随机游走

蚂蚁为搜索食物在空间的随机游走可用式 (8) 来模拟。

$$X(t) = [0, \text{cumsum}(2r(t_1) - 1), \dots, \text{cumsum}(2r(T) - 1)] \quad (8)$$

式中: cumsum 为累加和; t 为当前的迭代次数; T 表示最大的迭代次数; $r(t)$ 为一个随机函数。

$$r(t) = \begin{cases} 1, \text{rand} > 0.5 \\ 0, \text{rand} \leq 0.5 \end{cases} \quad (9)$$

式中: rand 为 (0, 1) 区间均匀分布的随机数。

在优化过程中更新蚂蚁和蚁狮的位置, 蚂蚁的位置记录在矩阵 \mathbf{M}_A , 蚁狮的位置记录在矩阵 \mathbf{M}_{AL} 。然后采用适应度函数来计算蚂蚁和蚁狮的适应度, 并将其适应度的值保存在对应矩阵中, 其中蚂蚁的适应度记录在矩阵 \mathbf{M}_{Oa} , 蚁狮的适应度记录在矩阵 \mathbf{M}_{oAL} ; 适应度函数维度即变量个数, 设置为 dim 。

为了保持蚂蚁在规定的搜索空间内随机游走, 通过式 (10) 对蚂蚁的位置进行标准化处理。

$$X_i^t = \frac{(X_i^t - a_i) \times (d_i^t - c_i^t)}{(b_i - a_i)} + c_i^t \quad (10)$$

式中: X_i^t 为第 i 维变量在第 t 次迭代时的标准化位置; a_i 和 b_i 分别为第 i 维变量随机游走步长的下界和上界; c_i^t 和 d_i^t 分别为第 i 维变量在第 t 次迭代时随机游走步长的下界和上界。

2) 蚁狮建造陷阱

在自然界中, 精英度高的蚁狮会建造更大的陷阱来增加它们的生存机会。为了对此进行模拟, ALO 算法利用轮盘赌操作根据适应度选择蚁狮建造陷阱, 轮盘赌选择操作可以帮助蚁狮有更多的机会捕捉到蚂蚁, 增加种群多样性。

3) 蚂蚁落入陷阱

蚁狮陷阱对于蚂蚁随机游走的影响定义如下:

$$c_i^t = \text{Antlion}_i^t + c^t \quad (11)$$

$$d_i^t = \text{Antlion}_i^t + d^t \quad (12)$$

式中: Antlion_i^t 表示在第 t 次迭代中第 i 只蚁狮的位置; c^t 和 d^t 分别表示第 t 次迭代中所有变量的下界与上界。

4) 蚂蚁滑向陷阱中心

当蚁狮发现蚂蚁落入陷阱会把沙子抛出陷阱, 防止蚂蚁逃脱, 使蚂蚁快速陷入陷阱中心, 蚂蚁随机游走的边

界范围自适应减小, 这种行为表达式如下:

$$c^t = \frac{c^t}{I} \quad (13)$$

$$d^t = \frac{d^t}{I} \quad (14)$$

$$I = 10^w \frac{t}{T} \quad (15)$$

$$w = \begin{cases} 2, t > 0.1T \\ 3, t > 0.5T \\ 4, t > 0.75T \\ 5, t > 0.9T \\ 6, t > 0.95T \end{cases} \quad (16)$$

式中: t 为当前迭代次数; T 为最大迭代次数; w 为由当前迭代次数决定的常数, 可以调整蚂蚁滑向蚁狮的速度。

5) 精英策略

精英策略是 ALO 算法的一个重要特性, 在精英化过程中, 会保存到目前为止每次迭代中适应度最高的蚁狮, 并将其设置为精英蚁狮。精英蚁狮能够在迭代过程中影响所有蚂蚁的随机游走, 蚂蚁的位置由精英蚁狮和轮盘赌选择的蚁狮联合决定, 表达式如下:

$$\text{Ant}_i^t = \frac{R_A^t + R_E^t}{2} \quad (17)$$

式中: Ant_i^t 为第 t 次迭代时第 i 只蚂蚁的位置; R_A^t 为第 t 次迭代时围绕轮盘赌选择的蚁狮游走后的位置; R_E^t 为第 t 次迭代时围绕精英蚁狮游走后的位置, 游走位置由式 (8) ~ (10) 更新。

6) 重建陷阱

在蚂蚁被蚁狮捕获后, 会评估蚂蚁新的位置, 当蚂蚁比对应的蚁狮适应度更高时, 就会捕获猎物, 蚁狮的位置将更新为被捕获蚂蚁的位置, 并在此重建陷阱, 新的陷阱将有更大几率捕捉到猎物。这种行为表达式如下:

$$\text{Antlion}_j^t = \text{Ant}_i^t \text{ if } f(\text{Ant}_i^t) > f(\text{Antlion}_j^t) \quad (18)$$

1.3 改进的蚁狮优化算法

传统的 ALO 算法具有良好的探索与开发能力, 蚂蚁围绕精英的随机游走保证了优化过程的收敛性, 轮盘赌选择方法在一定程度上提高了全局搜索能力。然而, 该算法仍然存在如下问题: 蚁狮的捕食陷阱边界随着迭代次数的增加而线性缩小, 游走边界比较单一, 容易损失种群多样性, 算法易陷入局部最优; 蚂蚁的随机游走易被限制在精英蚁狮周围, 损失全局探索与开发能力。针对以上情况, 对蚁狮算法加以改进, 提出 IALO 算法提高了种群的多样性和全局探索与开发的能力, 避免陷入局部最优, 提高了收敛精度。

1) 动态自适应调整边界

在原始 ALO 算法中, 由式 (13) ~ (16) 可知, 陷阱边

界大小随迭代次数增加而线性递减,然而这种机制并不能动态反映当前的性能,降低了算法的多样性。针对此情况提出自适应调整边界对式(15)进行改进,改进后的表达式如下:

$$I = 10^w \frac{t}{T} \cdot \left(1.3 - \cos\left(\frac{t\pi}{2T} \cdot rand\right) \right) \quad (19)$$

式中: $rand$ 为 $(0, 1)$ 间均匀分布的随机数, $(1.3 - \cos(\frac{t\pi}{2T} \cdot rand))$ 在 $(0.3, 1.3)$ 区间内非线性递减。改进后的表达式增加了一个动态参数,使陷阱边界大小呈现非线性递减趋势,动态调整陷阱边界范围,增加了蚂蚁围绕蚁狮随机游走的多样性与随机性,提高了算法的全局探索能力。

2) 加权精英策略

在原始 ALO 算法中,根据式(17)可知,蚂蚁的随机游走大多被限制在精英蚁狮的周围,算法的全局探索能力较差。改进蚁狮算法针对此情况进行改进,对式(17)加入一个精英权重参数 δ ,该参数可以调整不同时期蚂蚁围绕精英蚁狮和轮盘赌选择的蚁狮随机游走所占比重,在迭代前期轮盘赌选择的蚁狮对蚂蚁随机游走影响较大,在迭代后期精英蚁狮对蚂蚁随机游走影响较大。加权精英策略能平衡算法不同时期的游走权重,有效提升 ALO 算法探索能力与开发能力,加权过程表示如下:

$$\delta = \delta_{\max} - t \frac{\delta_{\max} - \delta_{\min}}{T} + \xi \cdot rand \quad (20)$$

式中: δ_{\max} 和 δ_{\min} 分别表示最大和最小的惯性权重, ξ 是控制随机性的常数, $rand$ 为 $(0, 1)$ 间均匀分布的随机数。改进后的蚂蚁游走表达式如下:

$$Ant_i^t = \frac{(2 - \delta) \cdot R_A^t + \delta \cdot R_E^t}{2} \quad (21)$$

2 IALO-SVR 模型

在 SVR 模型中,惩罚因子 C 用来调节模型的泛化能力,核函数参数 σ 用来控制模型的拟合能力,选取合适的 C 和 σ 的能有效提升 SVR 模型的预测性能,避免陷入过拟合或欠拟合。本文采用 IALO 算法对 SVR 关键参数全局寻优,选取全局最优参数组合 (C, σ) ,得到 IALO-SVR 预测模型,有效提升了收敛速度,避免陷入局部寻优,提升模型的预测性能。

该算法的流程如图 1 所示,具体步骤如下。

1) 数据预处理

训练模型前,需要对数据进行预处理,将样本数据特征归一化,预处理后的数据分为训练数据和测试数据,归一化表达式如下:

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (22)$$

式中: y 和 y' 分别表示训练数据归一化前后的样本特征值; y_{\min} 表示样本特征数据中的最小值; y_{\max} 表示样本特征数据中的最大值。

本文实验用电池额定容量损失来表示 SOH^[13],其公式定义如下:

$$SOH = \frac{C_i}{C_0} \times 100\% \quad (23)$$

式中: C_i 为第 i 次放电循环的电池容量; C_0 为电池额定容量。

2) 模型参数寻优

(1) 模型参数设置,综合寻优效率与精度,本模型设置 IALO 算法中蚁群和蚁狮数量为 $Ant_n = Antlion_n = 20$,适应度函数维度 $dim = 2$,最大迭代次数 $T = 100$,设置 SVR 中惩罚因子 C 和核函数参数 σ 的参数范围上、下界均为 $(0.01, 100)$ 。

(2) 种群随机初始化,IALO-SVR 算法中每只蚂蚁和蚁狮对应一组 SVR 的待优化参数组合 (C, σ) ,根据步骤(1)中设置的惩罚因子 C 和核函数参数 σ 取值范围对蚂蚁和蚁狮游走位置进行随机初始化,实现对所有蚂蚁和蚁狮个体的并行搜索。

(3) 计算适应度函数值,将每只蚂蚁和蚁狮的空间向量 (C, σ) 作为参数代入 SVR 进行训练,根据均方误差 (MSE) 建立的适应度函数式(24)对蚂蚁和蚁狮的适应度排序,并将蚁狮种群中适应度值最优的个体作为当前精英蚁狮 $Elite$,迭代次数 $t = 1$ 。

$$MSE = \frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2 \quad (24)$$

式中: MSE 为代表实际值与预测值之间的均方误差; \hat{y}_n 为第 n 个训练样本的预测值; y_n 为第 n 个训练样本的实际值; N 为训练样本的样本数量。

(4) 更新适应度与位置,在每次迭代中,通过轮盘赌操作对蚁狮进行贪婪选择,根据式(17)和(18)更新所有蚂蚁和蚁狮的位置,并重新计算蚂蚁和蚁狮的适应度值,取适应度值前 50% 的位置作为新一代蚁狮的位置,将适应度最好的位置更新为新一代精英蚁狮的位置。

(5) 判断终止条件,判断 IALO-SVR 算法是否达到最大迭代次数 T ,若满足则输出精英蚁狮 ($Elite$) 的空间向量 $(C_{Elite}, \sigma_{Elite})$ 即 SVR 惩罚因子 C 和核函数参数 σ 的最优参数,否则迭代次数增加 1,并返回步骤(4)。

3) 预测锂电池 SOH

通过步骤 2) 获得 SVR 最优参数组合,并依此参数训练 SVR 模型得到最终预测模型,输出预测的 SOH 与测试数据对比,验证模型的预测准确率。

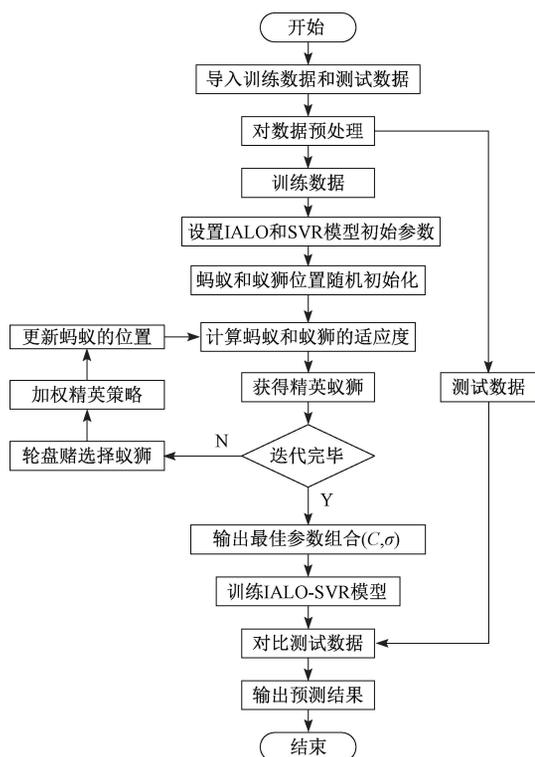


图 1 IALO-SVR 算法流程

Fig. 1 Flowchart of IALO-SVR algorithm

3 实验与分析

3.1 锂离子电池数据分析

本实验采用的锂离子电池数据集来自于 NASA PCoE 研究中心^[14],该数据集包括多个商用锂离子 18650 型可充电电池的充放电实验数据,本文选择 5、6、7 号电池作为实验对象,电池额定容量为 2 Ah,充电截止电压为 4.2 V。对 3 个锂离子电池(5、6、7 号)在室温(24 ℃)下以 3 种不同的运行方式(充电,放电和阻抗测试)运行的实验数据进行记录。充电过程以 1.5 A 的恒定电流(CC)模式进行充电,直到电池电压达到 4.2 V,然后以恒定电压(CV)模式继续充电,直到充电电流降至 20 mA,充电过程结束。放电过程以 2 A 的恒定电流进行放电,直到电池 5、6、7 的电池电压分别降至 2.7、2.5、2.2 V。阻抗测量过程以 0.1 Hz~5 kHz 的电化学阻抗谱(EIS)频率扫描进行。重复的充电和放电循环会导致电池加速老化,当测试电池容量降至额定容量的 70%时,达到电池寿命终止标准,测试实验将停止。3 块电池均进行 168 次充放电循环,提取特征因子和 SOH 构成实验样本,本实验将充电持续时间 TC 、恒压充电持续时间 TV 和充放电循环次数 CN 作为特征输入,电池 SOH 作为回归量,得到样本集 $S = \{(x_1, y_1), \dots, (x_n, y_n)\}$,其中 x_i 为第 i 个样本

中由 TV 、 TC 、 CN 构成的三维特征向量,和 y_i 为第 i 个样本的回归值。

5、6、7 号电池的 SOH 变化曲线如图 2 所示,可以看出经过多次充放电循环后,电池的 SOH 出现不同程度的衰退,电池在退化过程中具有一定的容量再生能力,使得电池 SOH 与电池循环次数呈非线性关系。与 6 和 7 号电池相比,5 号电池的 SOH 衰减趋势较为平缓,达到寿命终止标准前的有效样本最多,本文将其作为典型例子进行分析。

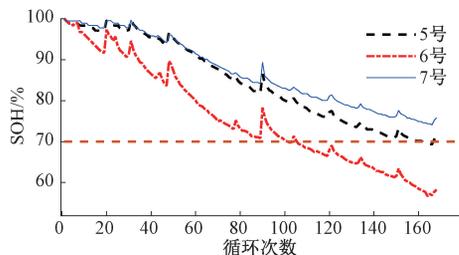


图 2 3 种电池的 SOH 变化曲线

Fig. 2 The SOH variation curves of three types of batteries

3.2 提取特征因子

特征因子的选取对数据驱动方法的预测准确性起着决定性作用,选取合适的特征因子能显著提升模型的预测效果。电池退化主要受其工作温度、电压和电流的影响,其退化程度也体现在这 3 个特性的变化上^[15];考虑到电池的放电过程容易受使用习惯和外界因素影响,难以从中提取稳定特征因子,相反,充电过程相对稳定,更容易提取稳定和具有代表性的特征因子来预测 SOH。本实验从充电数据中提取平均充电温度 AT 、恒流充电持续时间 TC 、恒压充电持续时间 TV 、充放电循环次数 CN 作为特征进行分析。

以 5 号电池为例,其不同循环次数的充电曲线如图 3 所示,充电过程分为恒流充电阶段和恒压充电阶段,随着循环次数的增加,采用恒流模式充电达到截止电压的时间逐渐减少,恒压充电时间逐渐增加,分别与电池 SOH 衰减呈现一定的正负相关性,可以作为特征因子表征 SOH。

为了评估样本输入特征与电池 SOH 的相关性,采用皮尔森相关系数(Pearson correlation coefficient)^[16]对特征因子与 SOH 的相关性进行分析,由 Pearson 相关系数原理可知,当相关度的绝对值大于 0.9 时,表明该特征因子与 SOH 极其相关;以 5 号电池为例,如表 1 所示, TC 、 TV 、 CN 与 SOH 的皮尔森相关系数绝对值均大于 0.9,相关性极强, AT 与 SOH 的相关性则很弱。考虑到降低 BMS 处理负担和提升运算效率,本实验选择将充电持续时间 TC 和恒压充电持续时间 TV 以及充放电循环次数 CN 作为特征输入,表示为 $X_i = [TC_i, TV_i, CN]$ 。

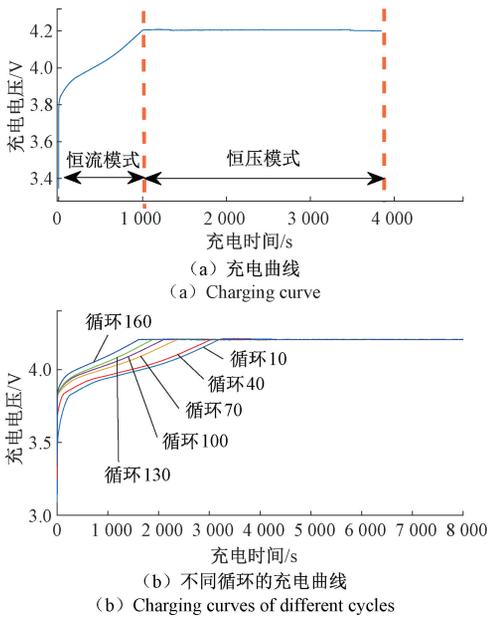


图3 5号电池在不同循环次数下充电电压的变化曲线
Fig.3 Charging voltage curves of battery no. 5 at different cycle numbers

MAPE 和 RMSE 的值越小表明误差越小,模型性能更优秀,预测效果更准确, R^2 表示预测值与估计值的拟合程度,最大为 1,数值越大表示数据拟合程度越好。

3.4 算法性能分析

1) IALO-SVR 算法预测性能分析本实验基于 MATLAB2019a 平台,为了验证 IALO-SVR 算法的预测性能,设计了两种方案进行对比,对于 168 个样本,方案 S1 选择前 80 个样本作为训练样本集,剩余的 88 个样本作为测试样本集;方案 S2 选择前 100 个样本作为训练样本集,剩余的 68 个样本作为测试样本集。

两种实验方案预测误差如表 3 所示,对于各种类型的电池,方案 S2 的预测性能均优于方案 S1,表明随着样本数据的增加,IALO-SVR 算法的预测精度得到提升,拟合程度更好。在 S2 方案下,5 号电池的 RMSE 和 MAPE 相对于 S1 分别降低了 0.19 和 0.49%, R^2 增加了 0.002 93;6 号电池的 RMSE 和 MAPE 相对于 S1 分别降低了 0.33 和 0.06%, R^2 增加了 0.010 66;7 号电池的 RMSE 和 MAPE 相对于 S1 分别降低了 0.25 和 0.04%, R^2 增加了 0.009 55。

表 2 IALO-SVR 预测性能

Table 2 IALO-SVR Predicted Performance

电池	方案	MAPE	RMSE	R^2
5 号	S1	0.67	0.40	0.992 55
	S2	0.18	0.21	0.995 48
6 号	S1	0.47	0.69	0.980 94
	S2	0.41	0.36	0.991 60
7 号	S1	0.20	0.44	0.985 13
	S2	0.16	0.19	0.994 68

以 5 号电池为例,在 S2 方案下电池的预测曲线和预测误差如图 4 所示,可以看出 5 号电池的 SOH 预测值与真实值之间的误差基本保持在 1% 以内,且能比较准确的预测电池 SOH 的变化趋势,与表 2 的实验数据相契合。

2) IALO-SVR 算法与现有预测算法性能比较

为了进一步验证 IALO-SVR 算法的预测性能,本实验选择现有的 IPSO-SVR 算法、GA-SVR 算法作为对比算法与 IALO-SVR 进行预测性能比较。在实验过程中,3 种算法均采用相同的参数与样本,选择前 100 个样本作为训练样本集,剩余的 68 个样本作为测试样本集,并用 3 种性能评价指标对预测结果进行评估。

表 3 为 3 种算法对 5、6、7 号电池 SOH 的预测性能比较结果,从表 3 可看出,在相同的条件下,IALO-SVR 算法的预测性能明显优于 IPSO-SVR 算法和 GA-SVR 算法,拟合程度更好,MAPE 和 RMSE 均有不同程度的降低;其 MAPE 和 RMSE 同 IPSO-SVR 相比在 3 种数据集上分别平均降低了 0.23% 和 0.29%, R^2 平均提升 0.011 69;IALO-SVR 的 MAPE 和 RMSE 同 GA-SVR 相比在 3 种数据集上分别平均降低了 0.29% 和 0.29%, R^2 平均提升 0.024 44。

表 1 特征因子与 SOH 的 Pearson 相关系数

Table 1 Pearson Correlation Coefficient between Characteristic Factor and SOH

特征	Pearson 相关系数
AT	0.012 0
TC	-0.976 8
TV	0.998 6
CN	-0.987 7

3.3 性能评价指标

为了对预测性能进行对比分析,采用百分比均值误差 (mean absolute percentage error, MAPE)、均方根误差 (root mean square error, RMSE) 和决定系数 R^2 (coefficient of determination) 3 个指标来评估 IALO-SVR 算法的性能。

绝对百分比均值误差为:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - Y'_i}{Y_i} \right| \times 100\% \quad (25)$$

均方根误差为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2} \quad (26)$$

决定系数为:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - Y'_i)^2}{\sum_{i=1}^n (Y_i - M)^2} \quad (27)$$

式中: n 为测试样本的数量; Y_i 为第 i 个样本的实际值; Y'_i 为第 i 个样本的预测值; M 为实际值的平均数。

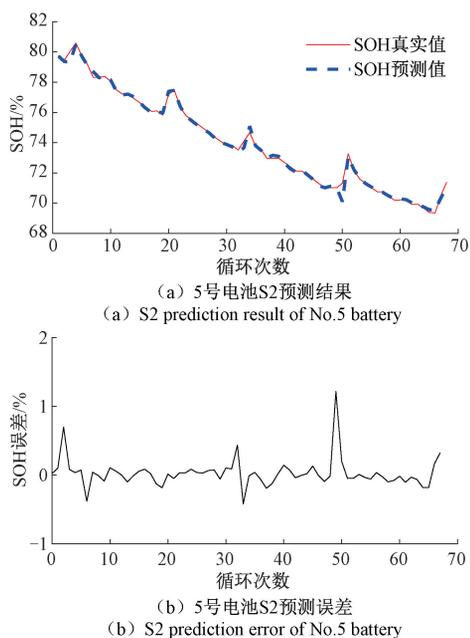


图 4 5 号电池的预测图与预测误差

Fig. 4 Prediction diagram and prediction error of No. 5 battery

为了更直观对比 3 种算法的预测性能,以 5 号电池为例,3 种算法对 5 号电池 SOH 的预测曲线及预测误差如图 5 所示,可看出 IALO-SVR 算法的预测值比其他两种算法更加接近真实值,预测曲线更加符合 SOH 的衰退曲线,并对锂电池发生能量再生时产生的局部波动具有很好的适应性,拥有更精确的预测性能,准确的对应了表 3 的实验数据,验证了提出方法的有效性。

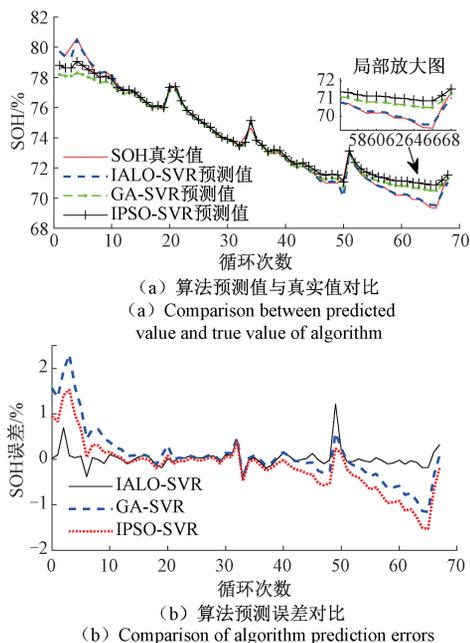


图 5 不同算法的预测曲线及误差

Fig. 5 Prediction curves and errors of different algorithms

表 3 3 种算法的预测性能比较

Table 3 Comparison of prediction performance of three algorithms

电池编号	算法类型	MAPE	RMSE	R^2
5 号	IPSO-SVR	0.55	0.59	0.986 93
	GA-SVR	0.52	0.63	0.982 07
	IALO-SVR	0.18	0.21	0.995 48
6 号	IPSO-SVR	0.49	0.62	0.975 44
	GA-SVR	0.41	0.41	0.989 02
	IALO-SVR	0.37	0.36	0.991 60
7 号	IPSO-SVR	0.37	0.43	0.984 31
	GA-SVR	0.64	0.58	0.991 35
	IALO-SVR	0.16	0.19	0.994 68

4 结 论

本文主要研究一种基于 IALO-SVR 的锂电池 SOH 预测方法,选取与电池 SOH 衰退高度相关的恒流充电时间、恒压充电时间、电池循环次数作为样本特征输入,电池 SOH 作为输出特征;通过 IALO 算法对 SVR 模型关键参数进行全局寻优,提升了预测模型的准确度与拟合度。在 NASA 公开数据集上的实验结果表明,IALO-SVR 方法的预测性能优于传统 SVR 方法,具有较高的预测精度和稳定性,预测误差基本保持在 1% 以内。下一步的工作是尝试将本方法应用于不同类型的电池,针对本方法的适用性展开进一步研究。

参考文献

[1] 刘大同, 宋宇晨, 武巍, 等. 锂离子电池组健康状态估计综述 [J]. 仪器仪表学报, 2020, 41(11): 1-18.
LIU D T, SONG Y CH, WU W, et al. Review of state of health estimation for lithium-ion battery pack [J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 1-18.

[2] 郑雪莹, 邓晓刚, 曹玉苹. 基于能量加权高斯过程回归的锂离子电池健康状态预测 [J]. 电子测量与仪器学报, 2020, 34(6): 63-69.
ZHENG X Y, DENG X G, CAO Y P. State of health prediction of lithium-ion batteries based on energy-weighted Gaussian process regression [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(6): 63-69.

[3] DENG Y, YING H, JIAQIANG E, et al. Feature parameter extraction and intelligent estimation of the State-of-Health of lithium-ion batteries [J]. Energy, 2019, 176: 91-102.

[4] 程泽, 杨磊, 孙幸勉. 基于自适应平方根无迹卡尔曼滤波算法的锂离子电池 SOC 和 SOH 估计 [J]. 中国

- 电机工程学报, 2018, 38(8): 2384-2393, 2548.
- CHENG Z, YANG L, SUN X M. State of charge and state of health estimation of li-ion batteries based on adaptive square-root unscented Kalman filters [J]. Proceedings of the CSEE, 2018, 38 (8): 2384-2393, 2548.
- [5] 沈佳妮, 贺益君, 马紫峰. 基于模型的锂离子电池 SOC 及 SOH 估计方法研究进展 [J]. 化工学报, 2018, 69(1): 309-316.
- SHEN J N, HE Y J, MA Z F. Progress of model based SOC and SOH estimation methods for lithium-ion battery [J]. CIESC Journal, 2018, 69(1): 309-316.
- [6] QIN T, ZENG S, GUO J. 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.
- [7] YANG D, WANG Y, 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.
- [8] MA C, ZHAI X, WANG Z, et al. State of health prediction for lithium-ion batteries using multiple-view feature fusion and support vector regression ensemble [J]. International Journal of Machine Learning and Cybernetics, 2018, 10(9): 2269-2282.
- [9] FENG X, WENG C, HE X, et al. Incremental capacity analysis on commercial lithium-ion batteries using support vector regression: A parametric study [J]. Energies, 2018, 11(9): 2323.
- [10] HU J, HAN K, LI Y, et al. TargetCrys: Protein crystallization prediction by fusing multi-view features with two-layered SVM [J]. Amino Acids, 2016, 48(11): 2533-2547.
- [11] CORTES C, VAPNIK V. Support-vector networks [J]. Machine Learning, 1995, 20(3): 273-297.
- [12] MIRJALILI S. The ant lion optimizer [J]. Advances in Engineering Software, 2015, 83: 80-98.
- [13] 刘大同, 周建宝, 郭力萌, 等. 锂离子电池健康评估和寿命预测综述 [J]. 仪器仪表学报, 2015, 36(1): 1-16.
- LIU D T, ZHOU J B, GUO L M, et al. Survey on lithium-ion battery health assessment and cycle life estimation [J]. Chinese Journal of Scientific Instrument, 2015, 36(1): 1-16.
- [14] AGOGINO A, GOEBEL K. Mill Data Set. BEST lab, UC Berkeley. NASA Ames Prognostics Data Repository [Z]. 2007.
- [15] GUHA A, PATRA A. State of health estimation of lithium-ion batteries using capacity fade and internal resistance growth models [J]. IEEE Transactions on Transportation Electrification, 2018, 4(1): 135-146.
- [16] BENESTY J, CHEN J, HUANG Y, et al. Pearson correlation coefficient [C]. Dictionary of Pharmaceutical Medicine. Vienna: Springer, 2009: 1-4.

作者简介



李强龙, 2018 年于湖南工业大学获得学士学位, 现为青岛大学硕士研究生, 主要研究方向为新能源汽车电控系统开发。

E-mail: 464574242@qq.com

Li Qianglong received his B. Sc. degree from Hunan University of Technology in 2018.

Now he is a M. Sc. candidate at Qingdao University. His main research interest includes development of electronic control system for new energy vehicles.



王凯 (通信作者), 2014 年于大连理工大学获得博士学位, 现为青岛大学教授、硕士生导师, 主要研究方向为储能元件、能源互联网。

E-mail: wkwj888@163.com

Wang Kai (Corresponding author) received his Ph. D. degree from Dalian University of Technology in 2014. Now he is a professor and M. Sc. supervisor at Qingdao University. His main research interests include energy storage components and energy internet.