

DOI:10.19651/j.cnki.emt.2106882

基于多指标最优权值融合的锂电池 SOH 估计*

魏业文^{1,2} 解国琳¹ 李梅¹ 周英杰¹

(1.三峡大学电气与新能源学院宜昌443002; 2.智慧能源技术湖北省工程研究中心宜昌443002)

摘要:为解决现有锂电池 SOH 在线估计方法精度不高的问题,提出利用改进粒子群算法(IPSO)优化支持向量回归(SVR)模型的方法。首先对所提取的健康指标进行关联分析,在利用启发式算法寻优 SVR 超参数的同时,对提取的多个健康指标融合的权值系数寻优,得到以最优数据序列训练的最优参数的 SVR 模型。采用美国国家航空航天局 PCoE 研究中心的 B5、B6、B7 3 组电池数据集对所提方法进行试验分析,结果表明,经算法优化后 3 组电池平均绝对百分误差(MAPE)和均方根误差(RMSE)分别降低了 62.3%、65.5%。最后通过与现有的预测模型进行对比,证明了所提方法具有更高的在线估计精度。

关键词: 健康状态;最优权值;改进粒子群算法;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:** 510.40

Estimation for state of health of lithium-ion batteries based on multi index optimal weight fusion

Wei Yewen^{1,2} Xie Yuanlin¹ Li Mei¹ Zhou Yingjie¹

(1. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China;

2. Hubei Provincial Engineering Research Center of Intelligent Energy Technology, Yichang 443002, China)

Abstract: In order to solve the problem of low accuracy of existing on-line SOH estimation methods for lithium batteries, propose an improved particle swarm optimization (IPSO) method to optimize the support vector regression (SVR) model. Firstly, the association analysis of the extracted health indicators is carried out, and the heuristic algorithm is used to optimize the hyper parameters of SVR. At the same time, the weights of the extracted multiple health indicators are optimized, and the SVR model with the optimal parameters trained by the optimal data sequence is obtained. Using three battery data sets B5, B6, B7 of the PCoE Research Center of the National Aeronautics and Space Administration to test and analyze the proposed method, the results show that the average absolute percentage error (MAPE) and root mean square error (RMSE) of the three groups of batteries are reduced by 62.3% and 65.5% respectively after the algorithm is optimized. Finally, by comparing with the existing prediction models, it is proved that the proposed method has higher online estimation accuracy.

Keywords: state of health; optimal weight; improved particle swarm optimization algorithm; support vector regression

0 引言

随着可再生能源、电动汽车和大规模储能系统的不断发展,锂离子电池以其质量轻、高能量密度、寿命周期长和安全性高等优点在能源系统中得到了广泛的应用。在实际应用中,循环往复的充放电周期会使得锂离子电池的容量呈现不规则下降的趋势,逐渐到达退役时刻,而在退役时刻之后电池电量和容量会下降更快,可能导致设备运行受损,

甚至造成灾难性故障。因此电池容量退化和健康状态 SOH 的在线监测可以保证电池在寿命结束时刻做退役处理,避免故障发生^[1-2]。

当前针对电池健康状态常用的估计方法有经验模型法、数据驱动法和融合方法。其中经验模型法通过建立影响电池使用过程健康状态的物理模型实现 SOH 估计,但电池老化是一个复杂的过程,受变电流和变温度等因素影响,高精度估计数学模型很难建立。因此在数据量充足的

收稿日期:2021-06-07

* 基金项目:国家自然科学基金资助项目(52007102)、湖北省重点研发计划项目(2020BAB110)资助

情况下,数据驱动法是电池 SOH 估计常用的方法。文献[3]利用 SVR 良好的泛化逼近能力估计锂离子电池健康状态;文献[4]通过建立遗传算法优化支持向量回归模型的相关参数对电池剩余寿命预测估计;文献[5]提出基于长短时记忆循环神经网络训练获取电池健康状态。其中神经网络由于需要大量样本进行训练,且容易产生过学习现象。SVR 模型有较多的参数依赖于经验选取,影响回归精度,因此可以采用优化算法寻找最优超参数优化 SVR。

此外,基于数据驱动方法的精度受特征指标选取的影响。大多数学者常选用单健康指标(HI)、或多健康指标估计 SOH。文献[6]采用等压放电时间作为健康指标实现电池 SOH 估计;文献[7]提出将等压差充电时间、等流差充电时间和等压差温度变化率多健康指标估计电池 SOH;文献[8]提出利用熵权法实现多健康特征指标融合提升电池 SOH 估计精度;而文献[9]提出 8 种可选健康指标做 SOH 预测估计。从当前研究现状可见,大多数研究人员忽略了单健康指标估计精度不足,或多健康指标耦合相关等问题,提取的健康指标数据不能最优表征电池 SOH。基于以上分析,本文提出基于改进粒子群算法优化健康指标融合最优权值和支持向量回归模型(IPSO-M-SVR)估计电池 SOH 的方法,利用灰色关联分析优选健康指标,利用改进粒子群算法改善传统算法易陷入局部最优的缺陷,并同时健康指标组合权值和 SVR 超参数寻优,以提升 SOH 在线估计精度。

1 构建电池健康指标

本文所用数据来自于锂电池 SOH 领域常用的美国国家航空航天局(NASA)的电池数据库,选用 B5、B6 和 B7 3 组具有代表性的数据集为研究对象。

1.1 健康指标的提取

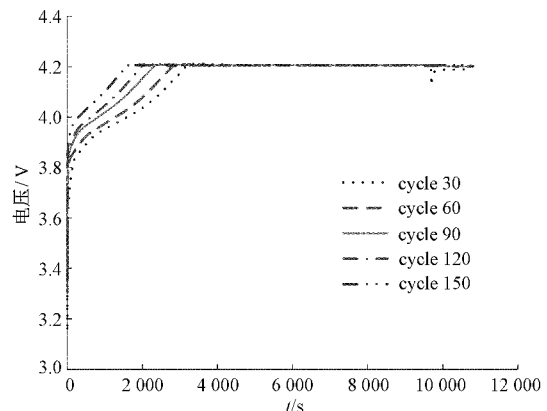
电池在使用中会逐渐老化,最大可用容量会逐渐降低,电池 SOH 即是对电池老化的量化描述。SOH 根据电池容量退化的表达式为:

$$SOH = \frac{Q_{\max}}{Q_{\text{rated}}} \quad (1)$$

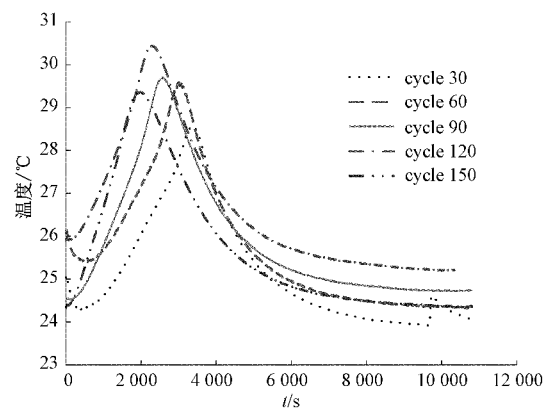
式中: Q_{\max} 为电池当前最大容量, Q_{rated} 为电池标称容量。因此对于电池 SOH 的估计就在于电池容量的精确获取。

研究发现,电池容量衰退的过程往往伴有复杂的退化机理,在在线监测过程中容量难以直接获取,但可以通过一些易获得的状态参数来间接表征电池 SOH。电池在使用过程中往往根据不同负载需求输出不同工况电流,而充电方式一般保持不变,并且电池放电过程中的极化效应会影响可放电容量,因此本文对充电数据进行分析,提取健康指标。以 B5 电池为例,不同充电周期数据如图 1(a)、(b) 所示。

由电化学机理可知,充电过程中锂离子从正极移动到负极,在两个电极上产生负的浓度梯度,在恒流(CC)最后



(a) 不同周期电压变化曲线



(b) 不同周期温度变化曲线

图 1 B5 电池充电数据

时刻达到最大值,然后在恒压(CV)阶段逐渐降低。随着电池老化,电池正极锂离子电荷量逐渐减少,并且固体电解质界面(SEI)的生长导致内阻增大,从而导致 CC 充电时间缩短。由电压曲线可以看出,随着周期数增大 CC 阶段时间明显降低。同时由于温度对电池健康状态有一定的影响,由数据集温度曲线可以看出,随着周期数增大电池到达温度峰值的时间明显缩短。因此基于以上分析,本文从 NASA 3 组电池充电数据集中提取 3 个与电池 SOH 的间接健康指标如图 2 所示。

1) 恒流充电时间(CCT),表征不同周期电池恒流充电模式的持续时间趋势。

2) 等压差充电时间(CDCT),若只考虑充电曲线某一点斜率,得到的结果可能会受到多种因素(电压波动、测试误差)的影响;同时由于电池充电起始电压随着周期数增大而上升,CDCT 可以解耦起始电压对 CCT 的影响,只表征电池充电电荷转移速率、电压上升速率。

3) 峰值温度时间(PTT),表征 CC 充电阶段不可逆热的综合性能。

由图 2 可以看出所提取的 3 组健康指标随着电池充放电周期数的增加而不均匀递减,且每组递减趋势各有差异,表明 3 种健康指标虽然都能在一定程度上反映电池 SOH,

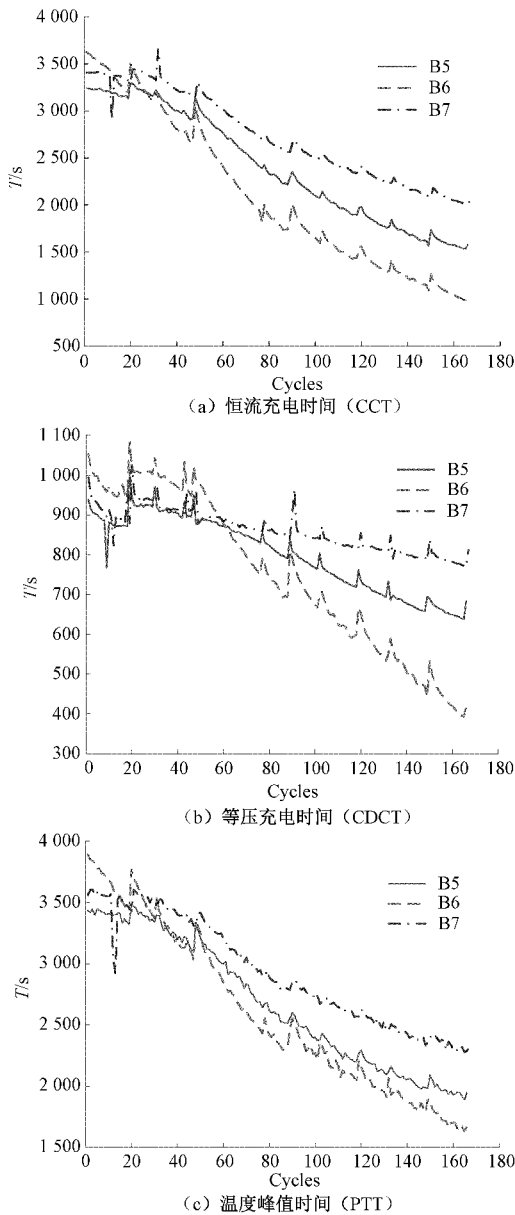


图 2 电池 SOH 间接健康指标

但与 SOH 之间的相关性并不相同。因此对健康指标与 SOH 之间的关联性和健康指标之间的关联性进行分析有助于提高预测模型训练效果。

1.2 多健康指标融合

由以上分析可知影响电池 SOH 的因素众多,为精确估计 SOH 需从多个指标角度综合分析,但大多数研究只评估了健康指标与 SOH 之间的关联性,忽略了各健康指标之间的耦合关系对 SOH 估计的影响。因此本文采用灰色关联分析评估所提取健康指标与 SOH 的关联性及其各指标之间的关联性,并将多指标融合(MIF)以提升 SOH 估计精度,流程步骤如下^[10]:

1) 建立数据评价体系

数据评价体系由比较序列和参考序列组成,若系统包

含 m 个评价指标, n 个评价体系,则可构成 $n \times m$ 的矩阵。其中最优序列和最劣序列或者具有代表性的某个序列可以被选作为参考序列,记作:

$$X_0 = (x_0(1), x_0(2) \cdots x_0(n)) \quad (2)$$

而在实际数据中,不同量纲的数据不能直接进行比较,为使系统分析结果准确,采用极值法对数据作归一化处理:

$$x'_{ij} = \frac{x_{ij} - x_j^{\min}}{x_j^{\max} - x_j^{\min}} \quad (3)$$

2) 灰色关联系数计算

对各个比较序列与参考序列做差求取其绝对值,可以得到其中最大值和最小值,计算关联系数:

$$\zeta_i(k) = \frac{\min_j \min_i |x_0(k) - x_i(k)| + \rho \max_j \max_i |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_j \max_i |x_0(k) - x_i(k)|} \quad (4)$$

式中: ρ 是分辨系数,介于 0~1 之间,一般取值 0.5。

3) 灰色关联度计算

在求得每个序列相对于比较序列之间关联系数之后,为了比较总体关联性,将关联系数加权求和取平均值:

$$r_{0i} = \frac{1}{m} \sum_{k=1}^m \zeta_i(k) \quad (5)$$

以 B5 电池为例,可以得到 1.1 节所取健康指标与 SOH 之间的关联度如表 1 所示。

表 1 健康指标与 SOH 的灰色关联度

指标	SOH	CCT	CDCT	PTT
SOH	1	0.948	0.833	0.936
CCT	0.948	1	0.819	0.863
CDCT	0.833	0.819	1	0.820
PTT	0.936	0.863	0.820	1

由表 1 可知提取的 3 个健康指标与 SOH 之间有很强的关联性,表明所取健康指标的可行性。同时各健康指标之间也有较强的耦合关系,考虑这种耦合关系提出多指标融合的方法,如式(6)所示。

$$MIF = a \cdot CCT + b \cdot CDCT + c \cdot PTT \quad (6)$$

$$s.t. \begin{cases} a, b, c \in (0, 1) \\ a + b + c = 1 \end{cases}$$

式中: a, b, c 为各健康指标融合特征系数,可由下文所提算法寻优使得 SOH 估计精确度最优。

2 基于改进 PSO-SVR 的锂电池 SOH 估计

2.1 支持向量回归算法

SVR 在由 Smola 和 Scholkopf 于 2004 年提出可用于数据预测后,被广泛用于解决分类和回归问题^[11-12],SVR 由给定训练集定义为:

$$\{(x_1, y_1) (x_2, y_2) \cdots (x_i, y_i)\} \in R^n \times R \quad (7)$$

式中: x_i, y_i 和 n 分别是输入向量、输出值和数据集。对于

给定的数据集,SVR 目标是将输入向量 x_i 映射到一个线性函数 $f(x_i)$ 上,并使 $f(x_i)$ 与 y_i 尽量接近, $f(x_i)$ 如下式所示。

$$y_i = f(x_i) = (\omega \times x_i) + b \quad (8)$$

式中: ω 为权向量; b 为常数。 $f(x_i)$ 和 y_i 之间存在一定误差,为提高模型预测精度,要使误差最小,误差函数 L 为:

$$\min L = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n |\xi_i^* + \xi_i| \quad (9)$$

$$s. t. \begin{cases} f(x_i) - y_i \leq \epsilon + \xi_i \\ y_i - f(x_i) \leq \epsilon + \xi_i^* \\ \epsilon \geq 0, \xi_i \geq 0, i = 1, 2, \dots, n \end{cases}$$

式中: ξ_i^* 、 ξ_i 为松弛因子; C 为惩罚因子; ϵ 为不敏感损失系数。引入拉格朗日乘子,式(8)推导为:

$$f(x) = \sum_{i=1}^n (a_i^* - a_i) K(x_i, x') + b \quad (10)$$

式中: a_i^* 和 a_i 为拉格朗日乘子; $K(x_i, x')$ 为核函数。

考虑径向基函数相对于其他核函数具有较高的预测效果,本文选择核函数为径向基函数,如式(11)所示。

$$K(x_i, x') = \exp(-\gamma \|x_i - x'\|^2) \quad (11)$$

式中: γ 为核函数宽度; $\|x_i - x'\|^2$ 为欧几里得距离。

SVR 的回归预测精度受 C 、 ϵ 和 γ 取值的影响^[13-14],可由下文所提算法寻优使得 SOH 估计精确度最优。

2.2 改进 PSO 算法

PSO 算法是利用群体中的个体对信息的共享从而使整个群体在寻优空间中有序运动获得问题最优解^[15]。在 PSO 中,每个粒子都代表优化问题的潜在解,粒子在寻优空间中的位置以一定的速度运动不断寻找最优解。粒子的位置和速度可更新为:

$$V(t+1) = \omega V(t) + c_1 r_1 (p_{best} - X(t)) + c_2 r_2 (g_{best} - V(t)) \quad (12)$$

$$X(t+1) = X(t) + V(t+1) \quad (13)$$

式中: ω 为惯性权重; c_1 、 c_2 为学习因子,分别取 2; r_1 、 r_2 为 $[0, 1]$ 之间均匀分布的随机数; p_{best} 为个体极值、 g_{best} 为全局极值; t 为粒子迭代次数。标准 PSO 虽然参数少且设置简单,但存在易陷入局部最优解、搜索范围小、精度低等缺点,需要对其进行改进以优化算法寻优效果。

1) 惯性权重系数和学习因子改进

PSO 算法中惯性权重 ω 可以表示粒子运动惯性的能力,惯性权重越大粒子群则更偏向全局搜索,惯性权重越小粒子群则更偏向局部搜索,因此考虑到算法初期需要较高的寻优速度以加强全局搜索能力,后期为提高精度要加强局部搜索能力,对惯性权重系数进行改进,采用动态非线性凹函数惯性权重如式(14)所示。

$$\omega(k) = \omega_{max} - (\omega_{max} - \omega_{min}) \left(\frac{2t}{T} - \left(\frac{t}{T} \right)^2 \right) \quad (14)$$

式中: ω_{max} 、 ω_{min} 为最大、最小权重,分别取 0.9、0.4; T 为最

大迭代次数, t 为当前迭代次数。

另一方面,在算法初期需增大学习因子,避免陷入局部最优,算法后期减小学习因子使算法更易得到全局最优解。因此动态学习因子如式(15)所示。

$$c = c_{max} - \frac{t}{T} (c_{max} - c_{min}) \quad (15)$$

式中: c_{max} 、 c_{min} 为最大、最小权重,分别取 2.5、0.5。

2) 粒子交叉变异策略

为了解决 PSO 算法存在的缺陷,本文提出增设选择、交叉和变异机制。其基本策略是根据 PSO 的粒子群适应度的高低进行排序,选择其中最优的一半粒子群,对这些粒子采取交叉变异策略,生成另一组粒子群,与交叉变异前的一半粒子群共同组成下一次迭代的粒子群。

(1) 交叉策略

交叉策略的制定一般需遵循既不要过度破坏优良粒子的性状,又要尽可能多的产生一批新的粒子,改善粒子群的多样性。因此本文选择将种群中个体两两配对,随机选取交叉点,两个个体互相交换交叉点前端部分,进而产生两个新的个体,如式(16)所示。

$$\begin{aligned} x'_i &= ax_j + (1-a)x_i \\ x'_j &= ax_i + (1-a)x_j \end{aligned} \quad (16)$$

式中: x'_i 、 x'_j 分别为交叉后产生的新个体, $a \in (0, 1)$ 。实行交叉策略与否取决于交叉概率的判定,选择交叉概率为 0.7。

(2) 变异策略

变异策略的制定需确定两个问题,变异点的选取与变异形式。本文制定变异策略为,选择粒子中的两点变异点,并对两个变异点之间的片段作翻转操作。如图 3 所示。



图 3 算法变异原则

同样的,实行变异策略与否取决于变异概率的判定,本文选择变异概率为 0.05。

2.3 IPSO-SVR 模型

在利用 SVR 进行电池 SOH 估计时,多个超参数和特征融合系数的取值会极大的影响估计精度,因此本文提出一种 IPSO-SVR 模型优化参数,以提高模型回归预测准确性。算法流程如图 4 所示。

3 实验分析

3.1 模型参数与评价指标

为验证本文所提方法的优越性,设计与 PSO-SVR、PSO-M-SVR 方法对比。设置 PSO 初始参数种群数量为 30,终止迭代次数为 200。为评价预测准确度,采用预测

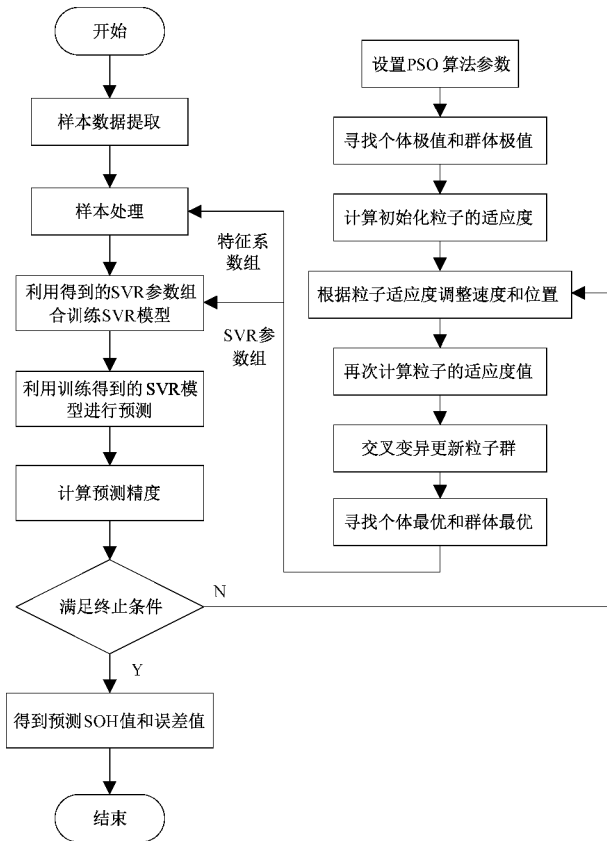


图 4 电池 SOH 估计流程

结果的平均绝对百分误差(MAPE)和均方根误差(RMSE)作为判断预测性能好坏的标准,如式(17)、(18)所示。以 B5 电池 SOH 为例,PSO 寻找最优参数适应度曲线如图 5 所示。

$$M_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - Y_i^*}{Y_i} \right| \times 100\% \quad (17)$$

$$R_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_i^*)^2} \quad (18)$$

式中: Y_i 为第 i 组电池 SOH 实际值; Y_i^* 为第 i 组电池 SOH 预测估计值, N 为样本数,取 168。

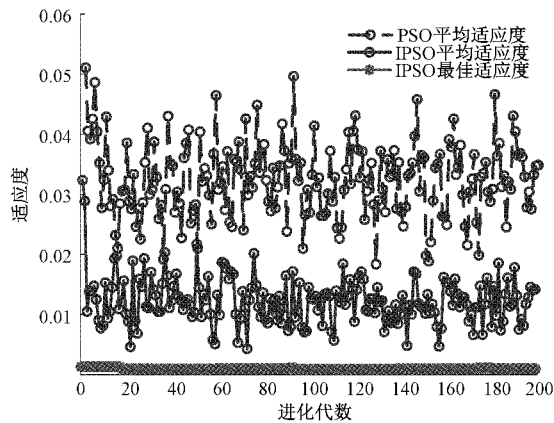
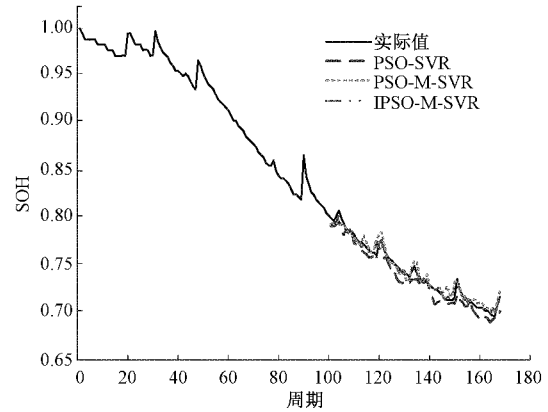


图 5 算法寻优过程

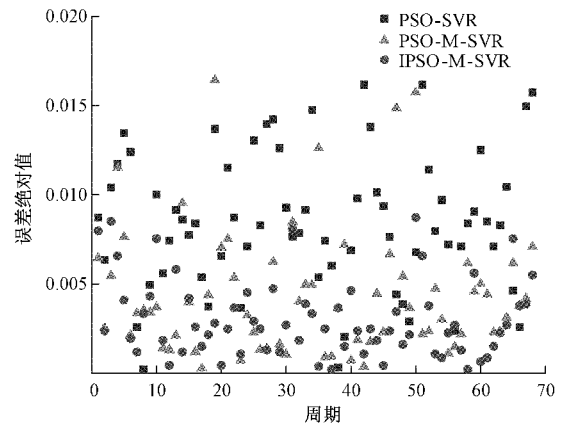
3.2 基于特征融合的 IPSO-M-SVR 预测性能分析

以 NASA 的电池数据集 B5、B6 和 B7 做预测分析。尽管 3 种电池初始容量不同,但初始 SOH 都为 100%。为保证本文所提方法预测 SOH 的准确性,设计电池数据集中前 100 周期为训练集,其余 68 周期为测试集。图 6、7 和 8 分别为 3 种电池在不同方法下的预测结果对比和误差结果对比。

由图 6~8 可以看出,本文所建立的 3 种 SVR 模型针对 3 组电池都可以较为精确的预测电池的 SOH,最大误

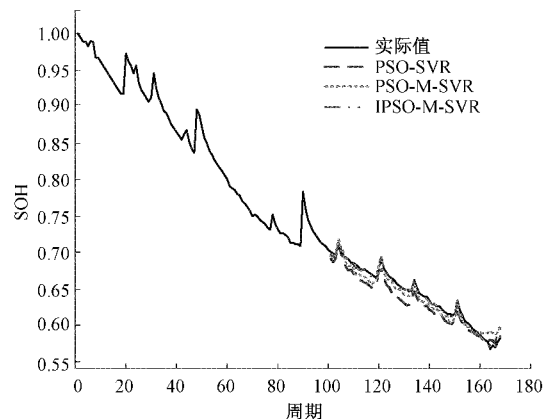


(a) SOH 预测结果



(b) 预测绝对误差

图 6 B5 电池预测结果



(a) SOH 预测结果

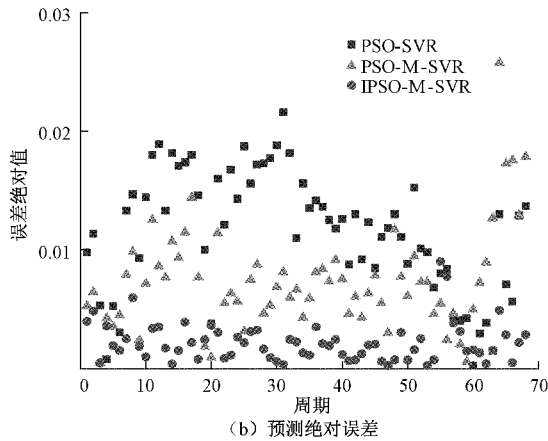
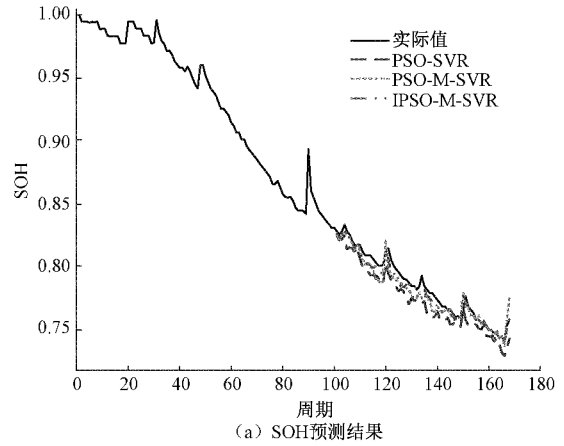


图 7 B6 电池预测结果

差均不超过 3%，可以满足电池 SOH 在线预测的精度需求。但是通过预测结果拟合程度和误差分析可以看出，本文所提基于 IPSO-M-SVR 模型的预测误差绝对值不超过 1.5%，优于 PSO-SVR 模型和 PSO-M-SVR 模型，更接近实际值。表 2 所示为 3 种预测模型针对 3 组电池数据集预测结果的平均绝对误差和均方根误差。

表 2 3 种模型在 3 组电池预测性能评价

电池编号	方法	$M_{MAPE}/\%$	R_{RMSE}
B5	PSO-SVR	1.15	0.009 3
	PSO-M-SVR	0.61	0.005 6
	IPSO-M-SVR	0.41	0.003 7
B6	PSO-SVR	1.78	0.012 6
	PSO-M-SVR	1.18	0.008 6
	IPSO-M-SVR	0.35	0.002 8
B7	PSO-SVR	1.37	0.011 8
	PSO-M-SVR	0.78	0.007 7
	IPSO-M-SVR	0.47	0.004 9



(a) SOH 预测结果

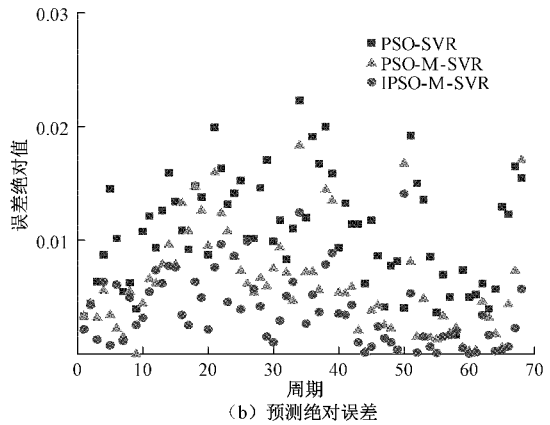


图 8 B7 电池预测结果

3.3 IPSO-M-SVR 算法与其他方法的比较

为了进一步验证 IPSO-M-SVR 模型在电池 SOH 预测估计性能方面的有效性和优越性，本文将与其他几种已发表的针对 NASA 电池数据集的预测模型进行了对比分析^[16]，如表 3 所示。

由表 3 可以看出，本文所提出的 IPSO-M-SVR 算法比已发表的 7 种预测模型具有更好的预测性能。在已发表的

表 3 8 种电池 SOH 预测模型的评估性能

电池类型	误差类型	LGPR	QGPR	CLGPR	SMK-GPR	P-MGPR	SE-MGPR	RTPF	IPSO-M-SVR
B5	$M_{MAPE}/\%$	23	1.9	1.6	1.65	1.55	1.38	0.76	0.41
	R_{RMSE}	0.017 1	0.015	0.013 6	0.013 8	0.013	0.012	0.006 8	0.003 7
B6	$M_{MAPE}/\%$	10.3	7.7	10.2	10.6	2.96	2.93	1.25	0.35
	R_{RMSE}	0.069	0.051 2	0.068 6	0.070 8	0.021	0.021 1	0.009 3	0.002 8
B7	$M_{MAPE}/\%$	1.9	5.4	1.7	1.91	1.09	1.02	0.43	0.47
	R_{RMSE}	0.015 9	0.055 2	0.017 3	0.018 8	0.011	0.010 7	0.004 4	0.004 9

7 种预测模型中，RTPF 预测效果最好，对 B5、B6、B7 电池的预测平均绝对误差和均方根误差都是最小的。相比之下，在 B5 电池和 B6 电池预测中，IPSO-M-SVR 的平均绝

对误差分别降低了 0.35、0.9，均方根误差分别降低了 0.003 1、0.006 5。尽管在 B7 电池的预测性能中，本文所提方法的平均绝对误差和均方根误差都略高于 RTPF 模型，

但相差并不多。因此综合来看,上述分析证明了本文所提 IPSO-M-SVR 的有效性和优越性。

4 结 论

本文提出了一种基于最优特征融合的 IPSO-SVR 的锂电池 SOH 估计方法。首先提取了能反映电池充电过程中的动态变化的健康指标用于估计 SOH,并利用灰色关联法分析了各健康指标与 SOH 之间以及各健康指标间的相关性,并提出利用最优权值特征融合的方法提升模型估计精度,然后利用改进的粒子群算法对 SVR 超参数和特征融合系数寻优,并与 PSO-SVR 模型和 PSO-M-SVR 模型进行了对比验证,结果表明本文所提的 IPSO-M-SVR 模型预测精确度更高,最后与以往已发表的多种 SOH 估计方法进行对比分析,结果证明了 IPSO-M-SVR 估计 SOH 具有更高的精确度。此外,本文只提取三种健康指标对预测模型训练,在未来工作中可尝试找出最优表征电池 SOH 的健康指标组合。

参考文献

- [1] 张金龙,佟微,孙叶宁,等. 锂电池健康状态估算方法综述[J]. 电源学报,2017,15(2):128-134.
- [2] 刘大同,宋宁晨,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.
- [3] WENG C, SUN J, PENG H. Model parametrization and adaptation based on the invariance of support vectors with applications to battery state-of-health monitoring [J]. IEEE Transactions on Vehicular Technology, 2015, 64(9): 3908-3917.
- [4] 王树坤,黄妙华,刘安康,等. 基于 GA-SVR 模型的锂离子电池剩余容量预测[J]. 汽车技术,2016(10):53-56,62.
- [5] 刘志明. 基于 LSTM-RNN 的动力电池 SOH 估计算法研究[D]. 桂林:桂林电子科技大学,2020.
- [6] 刘柱,姜媛媛,罗慧,等. 基于最优权阈值 ELM 算法的锂离子电池 RUL 预测[J]. 电源学报,2018,16(4):168-173.
- [7] 王文. 动力电池健康状态评估算法的研究[D]. 青岛:青岛科技大学,2020.
- [8] 朱荣荣. 充电曲线下多指标融合的锂电池剩余寿命研究[D]. 北京:北京交通大学,2020.
- [9] 宋哲,高建平,潘龙帅,等. 基于主成分分析和改进支持向量机的锂离子电池健康状态预测[J]. 汽车技术,2020(11):21-27.
- [10] 刘思峰,蔡华,杨英杰,等. 灰色关联分析模型研究进展[J]. 系统工程理论与实践,2013,33(8):2041-2046.
- [11] HASANIPANAH M, SHAHNAZAR A, AMNIEH H B, et al. Prediction of air-overpressure caused by mine blasting using a new hybrid PSO-SVR model [J]. Engineering with Computers, 2017, 33(1):23-31.
- [12] 杨彦茹,温杰,史元浩,等. 基于 CEEMDAN 和 SVR 的锂离子电池剩余使用寿命预测[J]. 电子测量与仪器学报,2020,34(12):197-205.
- [13] 陈家瑞,陈忠孝,秦刚,等. 基于 PSO 算法与 SVR 算法在企业直流配电网短期负荷预测的研究[J]. 国外电子测量技术,2020,39(12):70-73.
- [14] 赵杰,李英,吴晓云. 基于自适应 PSO 和 SVR 的矿坝位移预测[J]. 电子测量技术,2020,43(19):27-31.
- [15] 付春流,郑文芳,陈东洋,等. 锂电池剩余放电时间预测方法研究[J]. 电子测量技术,2020,43(10):57-62.
- [16] 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.

作者简介

魏业文,博士,主要研究方向为电池状态检测与管理。

E-mail: wyw0053@126.com

解园琳,硕士研究生,主要研究方向为储能电池状态监测与均衡控制。

E-mail: 1936735858@qq.com

李梅,硕士研究生,主要研究方向为系统仿真处理。

E-mail: Lm15872669017@126.com

周英杰,硕士研究生,主要研究方向为数据融合处理。

E-mail: 745847387@qq.com