

基于多特征组合的锂离子电池SOH估计

吴涵^{1,2}, 黄兴华^{1,2}, 乔振东³, 范元亮^{1,2}, 朱俊伟⁴, 陈金玉^{1,2}

(1. 国网福建省电力有限公司电力科学研究院, 福建 福州 350007;

2. 福建省高供电可靠性配电技术企业重点实验室, 福建 福州 350007;

3. 广东工业大学 自动化学院, 广东 广州 510006;

4. 国网福建省电力有限公司莆田供电公司, 福建 莆田 351199)

摘要: 准确估计锂离子电池的健康状态(SOH)是保证储能系统安全稳定运行的重要前提。提高SOH估计精度的关键在于合理选择能够反映锂离子电池SOH的健康特征。通过分析锂离子电池恒压充电阶段的电流特性,从恒压充电阶段电流曲线数据中提取了包含电流曲线首末点斜率、标准差和平均值的健康特征组合。为验证所提出特征组合的有效性,设计了基于核岭回归(KRR)和支持向量回归(SVR)的SOH估计模型,并完成了模型验证。实验结果表明,所提特征组合在不同模型下均能实现对SOH的高精度估计,具有良好的模型适应性。

关键词: 锂离子电池;健康状态估计;恒压充电阶段;核岭回归;支持向量回归

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed25435

SOH Estimation of Lithium-ion Batteries Based on Multiple Feature Combinations

WU Han^{1,2}, HUANG Xinghua^{1,2}, QIAO Zhendong³, FAN Yuanliang^{1,2}, ZHU Junwei⁴, CHEN Jinyu^{1,2}

(1. *Electric Power Research Institute of State Grid Fujian Electric Power Co., Ltd., Fuzhou 350007, Fujian, China*; 2. *Fujian Provincial Enterprise Key Laboratory of High Reliable Electric Power Distribution Technology, Fuzhou 350007, Fujian, China*; 3. *School of Automation, Guangdong University of Technology,*

Guangzhou 510006, Guangdong, China; 4. *State Grid Fujian Electric Power Co., Ltd.*

Putian Power Supply Company, Putian 351199, Fujian, China)

Abstract: Accurately estimating the state of health (SOH) of lithium-ion batteries is a crucial prerequisite for ensuring the safe and stable operation of energy storage systems. The key to improving the accuracy of SOH estimation lies in the rational selection of health characteristics that can effectively reflect the state of health of lithium-ion batteries. By analyzing the current characteristics of lithium-ion batteries during the constant voltage charging stage, a healthy combination of features containing the slope of the first and last points of the current curve, the standard deviation, and the mean value were extracted from the current curve data during the constant voltage charging stage. To validate the effectiveness of the proposed feature combination, SOH estimation model based on kernel ridge regression (KRR) and support vector regression (SVR) was designed, and model validation was successfully completed. The experimental results demonstrate that the proposed feature combination can achieve high-precision SOH estimation across different models, exhibiting excellent model adaptability.

Key words: lithium-ion battery; state of health (SOH) estimation; constant voltage charging stage; kernel ridge regression (KRR); support vector regression (SVR)

为了实现节能减排,推动能源转型,新能源成为近年来的研究热点。我国在2020年的气候雄心峰会提出2030年风电、太阳能发电总装机容量将达到12亿kW以上^[1]。然而风、光发电的输

出具有波动性和间歇性特点,并网之后将对电力系统造成不利影响^[2]。不断发展的储能系统很好地解决了上述问题。由于锂离子电池具有诸多优点,如高功率密度、低自放电率和环保等,在新

基金项目: 国网福建省电力有限公司科技项目(52130422002F)

作者简介: 吴涵(1985—),男,硕士研究生,高级工程师,主要研究方向为电力储能应用,Email: wu_han@fj.sgcc.com.cn

型储能的容量占比达到了94.4%^[3]。然而,锂离子电池储能系统仍面临着一些挑战^[4]。电池管理系统是储能系统的重要组成部分,其功能是对储能系统中锂离子电池的运行状态进行实时监测^[5]。在锂离子电池运行状态中,健康状态(state of health, SOH)尤为重要,反映了锂离子电池当前的老化状态^[6]。当SOH退化到安全阈值以下时,电池发生安全事故的概率会增加,难以保证储能系统的安全运行,容易引发火灾、爆炸等,具有巨大隐患^[7]。因此,准确估计锂离子电池SOH对于储能系统安全稳定运行具有重要意义。目前常用的锂离子电池SOH估计方法主要包括模型估计方法和数据驱动估计方法^[8-9]。

基于模型的估计方法主要利用等效电路模型求出与SOH强相关的参数及指标,进而实现SOH估计。文献[10]基于一阶等效电路模型得出相关电流时间常数,并以此建立SOH与电流时间常数的关系,从而进行SOH估计。文献[11]在Thevenin等效电路基础上利用双自适应无迹卡尔曼滤波算法实现了对SOH及电池荷电状态的联合估计。文献[12]基于阻抗谱中频部分的等效电路模型,使用传荷电阻和固体电解质相界面膜电阻作为SOH衡量指标,对锂离子电池SOH进行了估计。该方法避免了传统电化学阻抗谱等效电路模型参数多、拟合困难的问题。基于等效电路模型对SOH进行估计,需要准确计算等效电路参数。而且,当锂离子电池的型号及工作环境不同时,其对应的等效电路模型及参数也会不同,使得选择与当前锂离子电池及工作环境匹配的最佳模型及参数存在困难^[13]。

随着人工智能的快速发展,越来越多研究人员将机器学习及深度学习算法应用到锂离子电池SOH估计,提出了基于数据驱动的数据SOH估计方法。常用的数据驱动算法包括高斯过程回归^[14]、长短期记忆网络^[15]和支持向量机^[16]等。

数据驱动估计SOH的步骤包括特征提取、训练和测试^[17]。特征提取是从电池充放电过程中提取相应的电流、电压、温度等信息。由于电池放电过程存在随机性,多数研究是从电池充电过程中进行特征提取^[18]。电池常用的充电策略通常分为两阶段,第一阶段为恒流充电,在充电过程中电池电压逐渐上升,到达一定电压值后进入第二阶段,即恒压充电阶段^[19]。其中,恒流充电阶段的容量增量(incremental capacity, IC)曲线与电池老

化有着联系,IC曲线峰的面积、位置等特征与电池内部锂离子的化学反应密切相关^[20]。文献[21]使用IC曲线进行特征提取,然后对数据进行处理,结合BP算法估计电池SOH。文献[22]提出基于IC分析和电池运行特性结合的锂离子电池SOH估计方法,并且提出了一种偏差矫正模型增强了数据驱动框架的泛化能力。然而,使用IC曲线估计电池SOH需要较低充电电流倍率下的恒流充电电压曲线数据,而且需要连续记录较长时间^[23]。因为储能系统通常要尽量避免运行在低SOC区间,从而减小对电池寿命的不利影响,因此储能系统实际运行工况通常难以满足基于IC曲线的SOH估计方法所需运行条件^[24]。

针对从恒流充电阶段提取特征面临的上述问题,文献[25]提出使用弛豫阶段电压数据估计SOH。通过对电池充电完成后弛豫阶段的电压曲线数据的统计学分析,提出使用充电完成后30 min的弛豫电压数据的方差、偏度和最大值作为健康特征,并开发了迁移学习模型用于SOH估计。然而,该方法需要锂离子电池在充电完成后静置较长时间,才能获得完整的弛豫特性曲线数据。

从恒压充电阶段提取健康特征,克服了充电起始点不确定性的影响,也无需在充电结束后将电池长时间静置,具有更强的实用性。文献[26]通过分析恒压充电阶段数据,提出使用恒压段的充电时间和电流信息熵作为特征组合估计SOH。然而,上述特征未能全面描述电池健康状态,仍需进一步挖掘恒压充电阶段数据包含的电池健康信息,从而提高对SOH的估计精度。

针对上述问题,本文提出了一种基于恒压充电电流多特征组合的锂离子电池SOH估计方法。首先,通过分析恒压充电阶段电流数据,提出了一组新的特征组合,包括电流曲线斜率、标准差和平均值。然后,通过相关性分析验证了所提出特征组合与SOH具有高相关性。最后,分别设计了基于核岭回归(kernel ridge regression, KRR)和支持向量回归(support vector regression, SVR)的SOH估计模型,对所提出的特征组合进行验证,结果表明所提出的特征组合可实现对SOH的准确估计。

1 健康特征提取

1.1 数据集介绍

本研究实验采用的电池老化数据集取自同

济大学清洁能源汽车工程中心公开的镍钴锰电池数据集和镍钴铝电池数据集^[25],在本文中分别定义为NCM数据集和NCA数据集。其中,电池类型为18650。

在NCM数据集中,有28个电池在45℃、充电电流0.5C、放电电流1C的工况下进行循环充放电实验;在NCA数据集中,有7个电池在25℃、充电电流0.25C、放电电流1C的工况下进行循环充放电实验,有28个电池在45℃、充电电流0.5C、放电电流1C的工况下进行循环充放电实验。电池老化循环实验均采用恒流-恒压充电模式与恒流放电模式。图1为NCM数据集的28个电池容量老化随循环周期数变化的曲线图。




图1 电池老化曲线

Fig.1 Battery aging curves

为了分析电池老化情况对恒压电流曲线的影响,本文以NCM数据集中CY45-05_1-#28电池为例,对比不同循环周期恒压充电段的电流曲线,如图2所示。可见,随着电池循环周期的增加,电流曲线形态呈现规律性的变化。为了全面描述不同循环周期下电流曲线的状态,本文使用多个统计学指标作为健康特征,包括电流曲线首末点斜率(I_s)、电流数据的标准差(I_{std})和平均值(I_{ave}),构成特征组合。




图2 不同老化程度下电池恒压充电电流曲线变化情况

Fig.2 Changes in constant voltage charging current curve of batteries under different aging levels

1.2 特征相关性分析

本文从恒压充电阶段的电流数据中,提取了

3个健康特征,分别为 I_s 、 I_{std} 和 I_{ave} 。采用皮尔逊相关系数(Pearson correlation coefficient, PCC),定量分析所提特征与锂离子电池SOH之间的相关性,如下式所示:

$$\rho = \frac{n \sum_{i=1}^n p(i)q(i) - \sum_{i=1}^n p(i) \sum_{i=1}^n q(i)}{\sqrt{n \sum_{i=1}^n [p(i)]^2 - [\sum_{i=1}^n p(i)]^2} \sqrt{n \sum_{i=1}^n [q(i)]^2 - [\sum_{i=1}^n q(i)]^2}} \quad (1)$$

式中: p 为所选健康特征; q 为电池SOH值; n 为样本总数。

当PCC越接近于±1,表示两组数据之间的相关性越强。以NCM数据集中的前9个电池为例,提取恒压充电阶段的电流数据,进行数据清洗和归一化处理,并使用相关性函数进行分析,结果如表1所示。可见,所提出的健康特征与SOH的PCC绝对值多数在0.9以上。PCC分析结果表明,所提特征与电池SOH有着较强关联性。

表1 健康特征的PCC分析结果

Tab.1 Results of PCC analysis of health characteristics

电池	I_s	I_{std}	I_{ave}
1#	-0.982	0.948	0.971
2#	-0.979	0.945	0.966
3#	-0.973	0.925	0.912
4#	-0.962	0.870	0.917
5#	-0.982	0.937	0.949
6#	-0.940	0.788	0.878
7#	-0.981	0.950	0.967
8#	-0.982	0.951	0.967
9#	-0.983	0.950	0.968

2 算法模型与原理

从1.1节所述电池的老化曲线可以看出,电池SOH的下降是一个非线性过程。为了更好地建立健康特征与电池SOH之间的非线性关系,本文采用了回归算法中常用的KRR算法^[27]和SVR算法^[28],设计电池SOH估计模型。

2.1 基于KRR的SOH估计模型

KRR是在岭回归算法(ridge regression, RR)的基础上加入核函数,使用核函数将自变量从低维空间映射到高维特征空间,从而使模型具有处理非线性数据的能力。

本文从恒压充电电流数据中提取 I_s 、 I_{std} 和 I_{ave} 特征,这3个特征对应一个电池SOH标签,特征与SOH之间可以形成一个回归模型,因此可以转

换为求回归模型参数的问题。

在线性系统中,求取回归模型参数向量 w 的函数为下式:

$$\min(1/2) \sum_{m=1}^n (y_m - w^T x_m)^2 \quad (2)$$

式中: y 为因变量; x 为特征数据样本。

RR算法在求取回归模型参数向量 w 的代价函数中引入了正则化约束项 $(1/2)\lambda \|w\|^2$ 以解决多重共线问题,此时代价函数表示为

$$\min(1/2) \sum_{m=1}^n (y_m - w^T x_m)^2 + (1/2)\lambda \|w\|^2 \quad (3)$$

式中: λ 为正则化约束项的参数,其作用是平衡训练误差与正则化项,在本文中该参数设置为0.1; $\|\cdot\|$ 为 Hilbert 空间范数。

为了描述 SOH 与特征数据的非线性关系,加入核函数。此时 RR 就成为了 KRR 算法。本文采用的核函数为高斯核函数,具体为

$$K(x_m, x_z) = \exp\left(-\frac{\|x_m - x_z\|_2^2}{2\sigma^2}\right) \quad (4)$$

式中: σ 为该核函数的滤波器带宽,决定着函数平滑程度。

2.2 基于 SVR 的 SOH 估计模型

SVR 算法相对于传统回归模型,在计算损失有一定偏差的容忍度。只有当电池 SOH 目标值与预测值的偏差大于一定值时才进行损失的计算,因此需要引入不小于 0 的松弛因子 ξ 和 ξ^* 。此时特征数据与电池 SOH 之间的回归问题就转化为求下式:

$$\min(1/2) \|w\|^2 + c \sum_{m=1}^n (\xi_m^* + \xi_m) \quad (5)$$

式中: c 为大于 0 的常数,作用为正则化,在本文中此参数设置为 10。

式(5)的约束条件为

$$\begin{cases} y_m - w^T x_m - b \leq \varepsilon + \xi_m \\ w^T x_m + b - y_m \leq \varepsilon + \xi_m^* \end{cases} \quad m = 1, 2, \dots, n \quad (6)$$

式中: b 为阈值; ε 为偏差参数。

求解上述问题常使用对偶理论,利用 Lagrange 乘数法得到:

$$\min(1/2) \sum_{m=1, z=1}^n (\alpha_m - \alpha_m^*) (\alpha_z - \alpha_z^*) \langle x_m, x_z \rangle \quad (7)$$

式中: α, α^* 为 Lagrange 乘子。

为了解决非线性问题,需要将数据映射到高

维空间,因此采用核函数如下:

$$K(x_m, x_z) = \langle \Phi(x_m) \Phi(x_z) \rangle \quad (8)$$

式中: $\Phi(\cdot)$ 为非线性函数,目的是将样本数据升维。

此时式(7)将变为

$$\min(1/2) \sum_{m=1, z=1}^n (\alpha_m - \alpha_m^*) (\alpha_z - \alpha_z^*) K(x_m, x_z) + \sum_{m=1}^s \alpha_m (\varepsilon - y_m) + \sum_{m=1}^s \alpha_m^* (\varepsilon + y_m) \quad (9)$$

本文使用的核函数为高斯核函数,具体如下:

$$K(x_m, x_z) = \exp\left(-\frac{\|x_m - x_z\|_2^2}{2\sigma^2}\right) \quad (10)$$

3 实验评价指标与流程

3.1 评价指标

为了更好地描述 SOH 估计结果,选取平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和决定系数(coefficient of determination, R^2) 3 种评价指标,公式分别为

$$MAE = \frac{1}{n} \sum_{i=1}^n |q_r(i) - q_e(i)| \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [q_r(i) - q_e(i)]^2} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n [q_r(i) - q_e(i)]^2}{\sum_{i=1}^n [q_r(i) - q_{ave}]^2} \quad (13)$$

式中: q_r 为实际 SOH 值; q_e 为电池 SOH 估计值; q_{ave} 为电池实际 SOH 的平均值。

3.2 实验验证流程

本文为了对所提取特征组合的有效性进行验证,使用了两种经典机器学习算法 SVR 和 KRR,基于所选择的特征组合设计 SOH 估计模型,并就估计结果进行对比分析。实验所用计算机设备 CPU 型号为 Intel (R) Core (TM) i7-7700 CPU @ 3.60 GHz, RAM 内存为 8 GB, 程序语言环境为 Python。实验验证流程如图 3 所示。

具体实验流程如下:

- 1) 根据数据集提取相应的恒压电流曲线数据,对采样数据进行特征提取,并提取电池 SOH 标签;
- 2) 划分训练集数据和测试集数据;
- 3) 进行数据标准化,将其转换为标准正态分

布,更好地适应机器学习模型;

4)建立两种机器学习算法模型KRR和SVR,使用训练集数据对模型进行训练,使用测试集数据对训练好的模型进行验证;

5)使用MAE, RMSE和R²对估计结果进行对比分析。

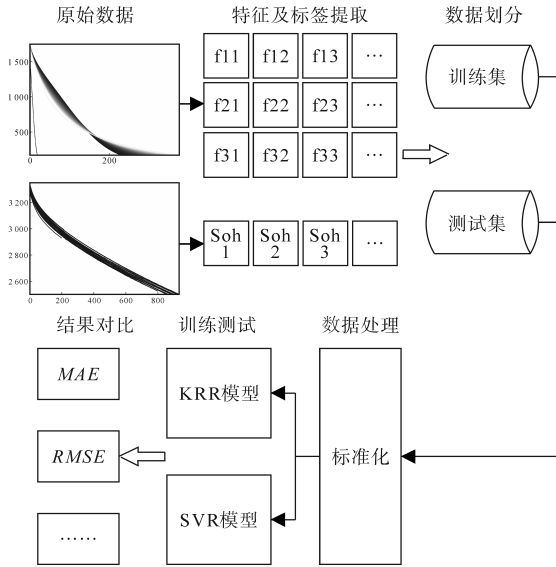


图3 实验验证流程

Fig.3 Experimental verification process

4 电池实验结果与分析

4.1 NCM 电池实验结果与分析

为了验证本文所提特征组合的有效性,使用本文所选NCM数据集的28个电池对KRR和SVR模型进行训练和测试。本文以电池为单元划分训练集与测试集,将1#,3#,7#,11#,13#,17#,21#,23#,27#电池的数据作为测试集,剩余19个电池的数据为训练集。同时,通过与现有特征组合进行对比来验证本文特征的优越性,具体对比的特征包括:恒压充电时间(即对比1)、恒压充电时间与恒压充电电流信息熵(即对比2)^[26]、弛豫电压曲线的方差、最大值和偏度(即对比3)^[25]。

4.1.1 KRR模型下不同特征组合对比实验

在KRR模型下的测试结果如表2所示。本文所提特征组合的测试结果中,电池SOH估计结果的MAE平均值为0.559%,RMSE平均值为0.874%,R²平均值为0.959。其中,1#,3#,7#,11#,13#,17#和21#这7个电池的MAE和RMSE均小于1%,最佳MAE值为0.278%。将本文所提特征组合与其它特征组合进行对比,情况如下:与对比1相比,仅有21#电池的SOH估计结果略差;与对比

2相比,仅有17#电池的SOH估计结果略差;与对比3相比,仅有1#和7#电池的SOH估计结果略差。可见,本文所提出的特征组合在大多数测试电池的情况下均优于3个对比,对于所有测试电池的平均估计精度也明显优于其他特征。

表2 基于KRR模型的NCM电池SOH估计结果

Tab.2 SOH estimation results of NCM cells basing on KRR model

电池	指标	本文	对比1	对比2	对比3
1#	MAE/%	0.415	1.132	0.609	0.305
	RMSE/%	0.648	1.209	0.822	0.384
	R ²	0.972	0.903	0.955	0.990
3#	MAE/%	0.491	1.221	0.720	1.128
	RMSE/%	0.827	1.543	1.180	1.231
7#	MAE/%	0.368	0.925	0.412	0.274
	RMSE/%	0.674	1.114	0.786	0.397
11#	MAE/%	0.632	1.448	0.778	1.213
	RMSE/%	0.789	1.484	0.934	1.269
13#	MAE/%	0.426	1.028	0.685	0.689
	RMSE/%	0.585	1.122	0.876	0.738
17#	MAE/%	0.278	0.310	0.258	0.391
	RMSE/%	0.754	0.573	0.372	0.528
21#	MAE/%	0.409	0.339	0.414	1.348
	RMSE/%	0.804	0.615	0.704	1.724
23#	MAE/%	1.400	2.461	1.804	2.421
	RMSE/%	1.573	2.531	1.881	2.479
27#	MAE/%	0.612	1.967	1.053	0.784
	RMSE/%	1.210	2.077	1.181	0.839
均值	MAE/%	0.559	1.203	0.748	0.950
	RMSE/%	0.874	1.363	0.971	1.065
	R ²	0.959	0.885	0.940	0.929

图4以1#,3#,7#和11#电池为例,给出了SOH估计结果图。可见,本文所提特征组合的估计结果误差较大的主要分布在高SOH区间,在低SOH区间能够有较小的估计误差。在低SOH区间能

够得到较为精准的SOH估计结果,对于储能系统的维护工作具有更加实用性的意义。因此,本文所提特征组合具有较强的实用意义。




图4 KRR模型下SOH估计结果

Fig.4 SOH estimation results under KRR model

4.1.2 SVR模型下不同特征组合对比实验

在SVR模型下的测试结果如表3所示。可见,本文所提特征组合在SVR模型下同样具有良好的性能,MAE均值为0.566%,RMSE均值为

0.903%, R^2 均值为0.958,明显优于其他特征组合。图5以1#,3#,7#和11#电池为例,给出了SOH估计结果图。可见,本文所提特征组合在SVR模型下也能够得到较好的SOH估计精度,证明了本文所提特征组合对不同机器学习模型的适应性。

表3 基于SVR模型的NCM电池SOH估计结果

Tab.3 SOH estimation results of NCM cells basing on SVR model

电池	指标	本文	对比1	对比2	对比3
1#	MAE/%	0.345	1.195	0.547	0.261
	RMSE/%	0.509	1.260	0.750	0.336
	R^2	0.983	0.895	0.963	0.993
3#	MAE/%	0.469	1.138	0.688	1.038
	RMSE/%	0.807	1.434	1.104	1.135
	R^2	0.892	0.660	0.799	0.787
7#	MAE/%	0.390	0.855	0.426	0.246
	RMSE/%	0.733	1.032	0.746	0.364
	R^2	0.958	0.917	0.956	0.990
11#	MAE/%	0.642	1.471	0.675	1.210
	RMSE/%	0.782	1.504	0.853	1.298
	R^2	0.980	0.925	0.976	0.944
13#	MAE/%	0.485	1.031	0.625	0.656
	RMSE/%	0.658	1.109	0.828	0.706
	R^2	0.987	0.962	0.979	0.985
17#	MAE/%	0.336	0.257	0.263	0.526
	RMSE/%	0.902	0.441	0.358	0.635
	R^2	0.963	0.991	0.994	0.982
21#	MAE/%	0.514	0.296	0.464	1.532
	RMSE/%	0.946	0.536	0.814	1.939
	R^2	0.975	0.992	0.982	0.897
23#	MAE/%	1.321	2.526	1.748	2.411
	RMSE/%	1.583	2.592	1.841	2.456
	R^2	0.925	0.798	0.898	0.819
27#	MAE/%	0.592	1.943	0.832	0.896
	RMSE/%	1.203	2.046	0.997	0.931
	R^2	0.960	0.884	0.973	0.976
均值	MAE/%	0.566	1.190	0.696	0.975
	R^2	0.958	0.892	0.947	0.930

4.2 电池类型及温度适应性实验

4.2.1 电池类型适应性实验

为分析本文所提特征组合对于不同类型电池SOH估计能力适应性情况,选取NCA数据集中CY45-05_1工况下的所有28个电池进行实验。将其中编号为1#,3#,7#,11#,13#,17#,21#,23#,27#电池作为测试集,剩余电池为训练集,实验结果如表4所示。在KRR模型下,MAE均值为

0.669%,*RMSE*均值为0.804%,*R*²均值为0.968;在SVR模型下,*MAE*均值为0.715%,*RMSE*均值为0.886%,*R*²均值为0.959。可见,表4所示NCA电池的估计结果与表2和表3所示NCM电池的估计结果接近,证明所提出的SOH估计方法能适应不同类型的电池。




图5 SVR模型下SOH估计结果

Fig.5 SOH estimation results under SVR model

4.2.2 温度适应性实验

为分析本文所提特征组合对环境温度的适

表4 NCA电池在45℃时的SOH估计结果

Tab.4 SOH estimation results of NCA cells with 45℃

	KRR			SVR		
	<i>MAE</i> /%	<i>RMSE</i> /%	<i>R</i> ²	<i>MAE</i> /%	<i>RMSE</i> /%	<i>R</i> ²
1#	0.638	0.755	0.984	0.603	0.782	0.982
3#	0.411	0.644	0.945	0.408	0.868	0.900
7#	0.684	0.836	0.950	0.754	0.868	0.946
11#	0.978	1.077	0.965	1.058	1.172	0.959
13#	0.283	0.361	0.996	0.355	0.463	0.994
17#	1.348	1.616	0.914	1.496	1.763	0.898
21#	0.816	0.887	0.976	0.803	0.900	0.975
23#	0.390	0.508	0.992	0.440	0.550	0.991
27#	0.471	0.551	0.990	0.515	0.610	0.988
均值	0.669	0.804	0.968	0.715	0.886	0.959

应性,选取NCA数据集中CY25-025_1工况下的全部7个电池。将其中编号为CY25-025_1-#2和CY25-025_1-#7的两个电池数据作为测试集,剩余电池数据作为训练集,实验结果如表5所示。在KRR和SVR模型下,电池SOH估计结果均具有较高精度,其中*MAE*均值和*RMSE*均值都小于1%,*R*²均值都高于0.95。因此,可以证明本文所提特征组合具有良好的温度适应性。

表5 NCA电池在25℃时的SOH估计结果

Tab.5 SOH estimation results of NCA cells with 25℃

	KRR			SVR		
	<i>MAE</i> /%	<i>RMSE</i> /%	<i>R</i> ²	<i>MAE</i> /%	<i>RMSE</i> /%	<i>R</i> ²
2#	0.751	0.819	0.933	0.765	0.831	0.931
7#	0.842	1.003	0.974	0.722	0.846	0.982
均值	0.796	0.911	0.954	0.743	0.839	0.956

5 结论

储能系统实际运行工况存在电池充电起始点不固定、充电结束后难以长时间静置的特点,导致基于恒流充电阶段数据和弛豫阶段数据的SOH估计方法难以适用。针对该问题,本文提出一种基于恒压充电电流多特征组合的锂离子电池SOH估计方法。通过分析恒压充电电流曲线包含的SOH相关信息,提出采用电流曲线斜率、标准差和平均值作为健康特征。所提出的健康特征较为全面地挖掘了恒压充电电流数据中的健康状态信息,从而保证了良好的SOH估计精度。在此基础上,设计了基于KRR和SVR的电池SOH估计模型,并完成了实验验证。最终的实验结果证明了所提出特征组合的有效性。本文为储能系统锂离子电池在不完整充电情况下的SOH估计提供了新的方法。未来将进一步分析充放电电流对电池老化规律和SOH估计精度的

影响,研究迁移学习方法以提高本文健康特征在不同电流倍率下的SOH估计精度。

参考文献

- [1] 代倩,吴俊玲,秦晓辉,等.提升局部区域新能源外送能力的储能容量优化配置方法[J].电力系统自动化,2022,46(3):67-74.
DAI Qian, WU Junling, QIN Xiaohui, et al. Optimal configuration method of energy storage capacity for improving delivery ability of renewable energy in regional area[J]. Automation of Electric Power Systems, 2022, 46(3): 67-74.
- [2] 符杨,魏钰柠,贾锋,等.分布式风电机组电压波动特性分析及平抑控制策略[J].中国电机工程学报,2020,40(14):4496-4505,4729.
FU Yang, WEI Yuning, JIA Feng, et al. The voltage fluctuation characteristic of distributed wind generators and its smoothing control strategy[J]. Proceedings of the CSEE, 2020, 40(14): 4496-4505, 4729.
- [3] 中国能源研究会储能专委会.中关村储能产业技术联盟.储能产业研究白皮书[DB/OL].(2023-04-07)[2023-10-18].
http://www.esresearch.com.cn/report/?category_id=26.
China Energy Research Association Energy Storage Special Committee. China Energy Storage Alliance. Energy Storage Industry Research White Paper[DB/OL]. (2023-04-07) [2023-10-18]. http://www.esresearch.com.cn/report/?category_id=26.
- [4] JIANG Lihua, LUO Zzhimin, WU Tianqi, et al. Overcharge behavior and early warning analysis of LiNi_{0.5}Co_{0.2}Mn_{0.3}O₂/C lithium-ion battery with high capacity[J]. Journal of The Electrochemical Society, 2019, 166(6): A1055-A1062.
- [5] BALASINGAM Balakumar, AHMED Mostafa, PATTIPATI Krishna. Battery management systems—challenges and some solutions[J]. Energies, 2020, 13(11): 1-19.
- [6] LIU Xiwen, LI Jia, YAO Zhuohong, et al. Research on battery SOH estimation algorithm of energy storage frequency modulation system[J]. Energy Reports, 2022, 2(8): 217-223.
- [7] 曹文昊,雷博,史尤杰,等.韩国锂离子电池储能电站安全事故的分析及思考[J].储能科学与技术,2020,9(5):1539-1547.
CAO Wenjiong, LEI Bo, SHI Youjie, et al. Ponderation over the recent safety accidents of lithium-ion battery energy storage stations in South Korea [J]. Energy Storage Science and Technology, 2020, 9(5): 1539-1547.
- [8] 党月懋,张雪纯,徐楚奕,等.基于温度变化率曲线的锂离子电池健康状态评估算法[J].电气工程学报,2022,17(3):58-65.
DANG Yuemao, ZHANG Xuechun, XU Chuyi, et al. Lithium-ion battery state of health assessment algorithm based on DT curve[J]. Journal of Electrical Engineering, 2022, 17(3): 58-65.
- [9] 方德宇,楚潇,刘涛,等.基于数据-模型驱动的锂离子电池健康状态估计[J].电气工程学报,2022,17(4):20-31.
FANG Deyu, CHU Xiao, LIU Tao, et al. Research on health assessment method of lithium-ion battery based on data-model hybrid drive [J]. Journal of Electrical Engineering, 2022, 17(4): 20-31.
- [10] 杨驹丰.基于等效电路模型的锂离子动力电池参数辨识与状态估计[D].南京:南京航空航天大学,2019.
YANG Jufeng. Equivalent circuit model based parameter identification and state estimation for lithium-ion batteries[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2019.
- [11] 王若琦,王晓佳,杨淇,等.基于双自适应无迹卡尔曼滤波算法的锂电SOC/SOH联合估计[J].机械设计与制造,2023(1):1-4,8.
WANG Ruoqi, WANG Xiaojia, YANG Qi, et al. Joint estimation of lithium battery SOC/SOH based on double adaptive untracked kalman filtering algorithm[J]. Machinery Design & Manufacture, 2023(1): 1-4, 8.
- [12] 常春,王少晋,苏广伟,等.改进模型的锂离子电池健康状态估计[J].电池,2022,52(6):646-650.
CHANG Chun, WANG Shaojin, SU Guangwei, et al. State of health estimation of Li-ion battery based on improved mode[J]. Battery Bimonthly, 2022, 52(6): 646-650.
- [13] WANG Limei, PAN Chaofeng, LIU Liang, et al. On-board state of health estimation of LiFePO₄ battery pack through differential voltage analysis[J]. Applied Energy, 2016, 168(15): 465-472.
- [14] ZHOU Ruomei, ZHU Rong, HUANG Chenggeng, et al. State of health estimation for fast-charging lithium-ion battery based on incremental capacity analysis[J]. Journal of Energy Storage, 2022, 51: 104560.
- [15] TIAN Jiaqiang, LI Siqi, LIU Xinghua, et al. Long-short term memory neural network based life prediction of lithium-ion battery considering internal parameters[J]. Energy Reports, 2022, 10(8): 81-89.
- [16] HU Xiaosong, XU Le, LIN Xianke, et al. Battery lifetime prognostics [J]. Joule, 2020, 4(2): 310-346.
- [17] SUN Hanlei, YANG Dongfang, DU Jiakuan, et al. Prediction of Li-ion battery state of health based on data-driven algorithm [J]. Energy Reports, 2022, 12(8): 442-449.
- [18] GONG Yadong, ZHANG Xiaoyong, GAO Dianzhu, et al. State-of-health estimation of lithium-ion batteries based on improved long short-term memory algorithm[J]. Journal of Energy Storage, 2022, 53: 105046.
- [19] ZHANG Zhaopu, MIN Haitao, GUO Hangang, et al. State of health estimation method for lithium-ion batteries using incremental capacity and long short-term memory network[J]. Journal of Energy Storage, 2023, 64: 107063.
- [20] FLY A, CHEN R. Rate dependency of incremental capacity analysis (dQ/dV) as a diagnostic tool for lithium-ion batteries [J]. Journal of Energy Storage, 2020, 29: 101329.
- [21] WEN Jianping, CHEN Xing, LI Xianghe, et al. SOH prediction of lithium battery based on IC curve feature and BP neural net-

(下转第40页)

er generation and marine environmental monitoring[J]. Technology and Market, 2021, 28(2): 40-42.

[3] 谢仲淇.面向海洋监测节点的能量收集装置研究[D].镇江:江苏科技大学,2022.
XIE Zhongqi. Research on energy collection devices for ocean monitoring nodes[D]. Zhenjiang: Jiangsu University of Science and Technology, 2022.

[4] 肖曦,摆念宗,康庆,等.波浪发电系统发展及直驱式波浪发电系统研究综述[J].电工技术学报,2014,29(3):1-11.
XIAO X, BAI N Z, KANG Q, et al. A review of the development of wave power system and the research on direct-drive wave power system[J]. Transactions of China Electrotechnical Society, 2014, 29(3): 1-11.

[5] 洪岳,潘剑飞,刘云,等.直驱波浪能发电系统综述[J].中国电机工程学报,2019,39(7):1886-1900.
HONG Y, PAN J F, LIU Y, et al. A review on linear generator based on wave energy conversion systems[J]. Proceedings of the CSEE, 2019, 39(7): 1886-1900.

[6] 黄磊,胡敏强,余海涛,等.直驱式波浪发电用全超导初级励磁直线发电机的设计与分析[J].电工技术学报,2015,30(2):80-86.
HUANG L, HU M Q, YU H T, et al. Design and analysis of a fully-superconducting primary-excitation linear generator for direct-driven wave energy generation[J]. Transactions of China Electrotechnical Society, 2015, 30(2): 80-86.

[7] HUANG L, HU M Q, CHEN Z X, et al. Research on a direct-drive wave energy converter using an outer-PM linear tubular generator[J]. IEEE Transactions on Magnetics, 2017, 53(6): 1-4.

[8] HOLM R K, BERG N I, WALKUSCH M, et al. Design of a magnetic lead screw for wave energy conversion[J]. IEEE Transactions on Industry Applications, 2013, 49(6): 2699-2708.

[9] 汤文成,徐楠楠.滚珠丝杆副发展及研究现状[J].机械设计与机械制造,2016,45(4):11-14.
TANG W C, XU N N. Review on the research of ball screw[J]. Machine Design and Manufacturing Engineering, 2016, 45(4): 11-14.

[10] 凌志健,赵文祥,吉敬华.高推力永磁直线作动器及其关键技术综述[J].电工技术学报,2020,35(5):1022-1035.
LING Z J, ZHAO W X, JI J H. Overview of high force density permanent magnet linear actuator and its key technology[J]. Transactions of China Electrotechnical Society, 2020, 35(5): 1022-1035.

[11] LING Z J, JI J H, WANG J B, et al. Design optimization and test of a radially magnetized magnetic screw with discretized PMs[J]. IEEE Transactions on Industrial Electronics, 2018, 65(9): 7536-7547.

[12] JI J H, LING Z J, WANG J B, et al. Design and analysis of a Halbach magnetized magnetic screw for artificial heart[J]. IEEE Transactions on Magnetics, 2015, 51(11): 1-4.

收稿日期:2023-10-19

修改稿日期:2023-12-22

(上接第32页)

work[J]. Energy, 2022, 261: 125234.

[22] ZHOU Litao, ZHANG Zhaosheng, LIU Peng, et al. Data-driven battery state-of-health estimation and prediction using IC based features and coupled model[J]. Journal of Energy Storage, 2023, 72: 108413.

[23] 刘翠翠,胡厚鹏,刘伟,等.退役锂离子电池老化机制及其健康状态表征[J].化学工程,2023,51(2):18-23.
LIU Cuicui, HU Houpeng, LIU Wei, et al. Characterization of aging mechanism and state of health for retired lithium-ion battery[J]. Chemical Engineering(China), 2023, 51(2): 18-23.

[24] WIKNER Evelina, BJORKLUND Erik, FRIDNER Johan, et al. How the utilised SOC window in commercial Li-ion pouch cells influence battery ageing[J]. Journal of Power Sources Advances, 2021, 8: 100054.

[25] ZHU Jiagong, WANG Yixiu, HUANG Yuan, et al. Data-driven capacity estimation of commercial lithium-ion batteries from voltage relaxation [J]. Nature Communications, 2022, 13(1): 2261.

[26] LUO Laijin, ZHANG Chaolong, TIAN Youhui, et al. State-of-health estimate for the lithium-ion battery based on constant voltage current entropy and charging duration[J]. World Electric Vehicle Journal, 2022, 13(8): 148.

[27] CHRISTMANN Andreas, XIANG Daohong, ZHOU Dingxuan. Total stability of kernel methods[J]. Neurocomputing, 2018, 289: 101-118.

[28] 孟安波,蔡涌烽,符嘉晋,等.基于CSO-SVR的低压架空线路谐波损耗评估[J].电力工程技术,2022,41(3):202-208.
MENG Anbo, CAI Yongfeng, FU Jiajin, et al. Harmonic loss evaluation of low voltage overhead lines based on CSO-SVR mode[J]. Electric Power Engineering Technology, 2022, 41(3): 202-208.

收稿日期:2023-10-18

修改稿日期:2023-12-21