

基于两阶段充电数据融合的储能系统锂离子电池 SOH 估计方法

范元亮^{1,2}, 朱俊伟³, 吴涵^{1,2}, 韩晓岚⁴, 黄兴华^{1,2}, 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. 国网福建省电力有限公司莆田供电公司, 福建 莆田 351199;

4. 广东工业大学 自动化学院, 广东 广州 510006)

摘要:准确估计锂离子电池的健康状态(SOH)对于优化储能系统的运行、管理和维护至关重要。现有从单阶段充电数据提取健康特征的方法,不能充分挖掘电池老化信息,不利于提高估计精度。针对该问题,提出了一种基于两阶段充电数据融合的储能系统锂离子电池 SOH 估计方法。通过融合恒压充电阶段与弛豫阶段的健康特征,充分挖掘两阶段充电数据包含的电池老化信息,提高了 SOH 估计精度。同时,所提出的健康特征组合无需使用恒流充电阶段数据,因此不受充电起始点不确定性的影响,更加适应储能实际工况。实验结果表明,所提出健康特征组合的 SOH 估计精度明显优于单阶段特征组合,绝对误差平均值为 0.66%,均方误差平均值为 0.85%,决定系数平均值为 0.97。

关键词:锂离子电池;健康状态估计;两阶段特征融合

中图分类号:TM912 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed25516

State of Health Estimation Method for Lithium-ion Batteries in Energy Storage Systems Based on Two-stage Charging Data

FAN Yuanliang^{1,2}, ZHU Junwei³, WU Han^{1,2}, HAN Xiaolan⁴, HUANG Xinghua^{1,2}, CHEN Jinyu^{1,2}

(1.State Grid Fujian Electric Power Research Institute, Fuzhou 350007, Fujian, China; 2.Fujian Provincial Enterprise Key Laboratory of High Reliable Electric Power Distribution Technology, Fuzhou 350007, Fujian, China; 3.State Grid Fujian Electric Power Co., Ltd. Putian Power Supply Company, Putian 351199, Fujian, China; 4.School of Automation, Guangdong University of Technology, Guangzhou 510006, Guangdong, China)

Abstract: Accurately estimating the state of health (SOH) of lithium-ion batteries is crucial for optimizing energy storage systems' operation, management, and maintenance. Existing methods that extract health features from single-stage charging data fail to exploit battery aging information fully, leading to a suboptimal estimation accuracy. In addressing this issue, a SOH estimation method for energy storage systems based on the fusion of two-stage charging data for lithium-ion batteries was proposed. Combining health features from both constant voltage charging and relaxation stages, the proposed method effectively mines aging information embedded in two-stage charging data, thereby improving SOH estimation accuracy. Additionally, the introduced health feature combination does not require the use of constant current charging stage data, making it less affected by the uncertainty of charging start points and more adaptable to practical energy storage conditions. Experimental results demonstrate that the proposed health feature combination significantly outperforms single-stage feature combinations, with an average absolute error of 0.66%, mean squared error of 0.85%, and an average coefficient of determination of 0.97.

Key words: lithium-ion batteries; state of health (SOH) estimation; two-stage features fusion

基金项目: 国网福建省电力有限公司科技项目(52130422002F)

作者简介: 范元亮(1979—),男,博士,高级工程师,主要研究方向为电力储能应用,Email: fyl_fjdky@sina.cn

通讯作者: 韩晓岚(2001—),女,本科,主要研究方向为电化学储能技术,Email: 270984956@qq.com

锂离子电池以其高能量密度、长周期寿命、低自放电率等独特优势,广泛应用于新能源发电、电动汽车等储能系统^[1-2]。然而,由过充、过热等因素引发的锂离子电池安全问题仍然存在^[3],准确评估电池的健康状态(state of health, SOH)具有重要作用。锂离子电池SOH通常用于评估电池的剩余寿命和性能退化程度。准确估计电池SOH,有助于提高储能系统的安全性和可靠性。

国内外针对如何准确估计锂离子电池SOH的问题开展了大量研究。数据驱动的SOH估计方法是当前的主流方法之一,其主要通过提取与SOH高度相关的健康特征,并采用数据驱动方法,如支持向量回归(support vector regression, SVR)^[4-8]、高斯过程回归(Gaussian process regression, GPR)^[9-12]、长短期记忆网络(long short-term memory, LSTM)^[13-18]、集成学习方法(extreme gradient boosting, XGBoost)^[19-21]等,建立SOH估计模型。

采用数据驱动方法实现锂离子电池SOH的准确估计,关键在于获得与锂离子电池容量退化高度相关的健康特征。现有特征提取方法,主要通过分析锂离子电池充电曲线中包含的老化信息,进而获取表征电池SOH的健康特征,具体包括恒流充电阶段特征、恒压充电阶段特征和弛豫阶段特征。在实际储能工况下,电池充放电取决于用户用电需求,使得电池很少经历完整的充放电过程。因此,基于恒流充电阶段特征的SOH估计方法受充电起始点不确定性影响,存在一定的局限性^[22]。

从恒压充电阶段或弛豫阶段数据提取健康特征,可以不受充电起始点不确定性的影响^[23]。文献[24]指出恒压充电阶段的动态特性具有更好的通用性,并提出了基于恒压充电时长、恒压充电容量、恒压充电电流等5种恒压充电阶段特征的SOH估计方法。文献[25]分析了恒压充电时长、充电容量、充电能量及其变化率与电池SOH的相关性,并采用恒压充电时长与恒压充电能量作为特征组合来构建SOH估计模型。文献[26]从弛豫阶段提取健康特征作为SOH估计模型的输入,获得了较高的估计精度。文献[27]从弛豫电压曲线中提取了6个统计特征并进行分析,发现使用由弛豫电压的最大值、偏度和方差组成的特征组合建立SOH估计模型时具有最好的效果。然而,上述方法只从单一阶段提取健康特征,未能充分挖掘充电数据中蕴含的电池老化信息,限

制了SOH的估计精度。

基于多充电阶段健康特征融合的SOH估计方法,可以克服上述问题。现有研究主要关注恒流充电阶段与恒压充电阶段的特征融合。文献[28]将恒流充电时长与恒压充电时长的比值作为SOH估计的健康特征。文献[29]采用恒流充电电压增长速率、恒压充电电流降低速率、恒压充电期间温度降低速率等6个健康特征,构建SOH估计模型。然而,这些方法需要电池在荷电状态为零的情况下开始充电,才能获取恒流充电阶段特征,因此受到充电起始点影响,难以适用于实际储能工况。

针对现有方法存在的上述问题,本文提出了一种基于两阶段充电数据融合的锂离子电池SOH估计方法,从恒压充电阶段和弛豫阶段同时提取健康特征来构建新的特征组合。其中,从恒压充电阶段提取6等分恒压充电电流区间时长作为健康特征;从弛豫阶段提取弛豫电压的香农熵、弛豫电压曲线的最大曲率作为健康特征。

1 实验数据集获取

本文采用文献[27]公开的数据集进行实验研究。该数据集采用可重复充放电的18650锂离子电池,以电池正极材料NCA, NCM和NCM+NCA作为数据集,从中随机选取5种工况进行实验,如表1所示。实验工况代号可定义为A-CYB-C/D,其中,A表示数据集,B表示工作温度,C表示充电电流倍率,D表示放电电流倍率。例如,NCA数据集在25℃下充电电流倍率为1C,放电电流倍率为1C对应的实验工况代号为NCA-CY25-1/1。

表1 电池数据集运行条件介绍

数据集名称	工作温度/℃	充电/放电电压/V	充电/放电电流倍率/C
NCA	25	4.2/2.65	1/1
	45		0.5/1
NCM	35	4.2/2.5	0.5/1
	45		0.5/1
NCA+NCM	25	4.2/2.5	0.5/4
			0.5/1

2 两阶段健康特征组合构建

2.1 恒压充电阶段健康特征提取

由于SOH一般可以用锂离子电池最大可用容量来定义,而充电时长与电池容量之间存在密

切的关系。同时,恒压充电阶段特定电流区间对应的时长会随电池老化而发生变化,因此可以从恒压充电阶段的区间充电时长信息中提取健康特征,并分析其与SOH的相关性。为保证数据采集的连续性与电池信息的相对完整性,本文采用恒压充电阶段后期,即与弛豫阶段紧密相连的区间时长作为健康特征。

基于上述分析,将整个恒压充电阶段按等电流间隔进行分段,并获取每段的对应时长。通过将恒压充电曲线按电流值平均分为 n 个电流等差区间,获得对应分界点的电流值如下:

$$I_n = [I_{n1}, I_{n2}, \dots, I_{n(i+1)}] \quad (1)$$

其中, n 表示电流区间数量, $i = 1, 2, 3, \dots, n$ 。

根据式(1)的电流值对恒压充电曲线进行划分,可以得到 n 个充电区间的对应时长如下:

$$t_n = [t_{n1}, t_{n2}, \dots, t_{ni}] \quad (2)$$

在式(2)所示区间时长中,取最后一个区间的充电时长作为健康特征,即 t_{nn} 。图1以 $n = 6$ 为例,给出了区间划分示意图。




图1 恒压充电阶段区间时长划分示意图

Fig.1 Schematic diagram of interval duration division during constant voltage charging stage

将恒压充电阶段最后一个区间的充电时长作为健康特征,在实际应用中具有易于获取的优点。由于恒压充电的截止电流为充电器预设值,因此只需采集到恒压充电阶段的起始电流,即可计算出最后一个区间的起始电流 I_{ni} 。在充电电流为 I_{ni} 时开始计时,并在电流减小至 $I_{n(i+1)}$ 时停止计时,即可获得最后一个区间的充电时长 t_{nn} 。由于该特征只使用了时长信息,无需保存该阶段的电流数据,可以有效减少数据量,避免信息冗余,降低数据处理的成本。

2.2 弛豫阶段健康特征提取

许多研究表明,弛豫电压与电池容量衰减有明显的关系^[27]。为了从弛豫电压数据中提取健康特征,本文采用数学统计量描述弛豫电压,并分

析其与SOH的相关性。

2.2.1 弛豫电压香农熵

锂离子电池弛豫阶段的电压数据存在一定的随机性,且随机性随电池老化程度而增加。香农熵被广泛应用于衡量数据的随机性^[30]。因此,可以用弛豫阶段电压数据的香农熵 U_{sha} 来描述电池的老化程度。

本文通过对弛豫电压数据进行香农熵处理,获取健康特征,具体方法如下:

$$U_{sha} = - \sum_{h=1}^q p(w_h) \log [1/p(w_h)] \quad (3)$$

式中: U_{sha} 为弛豫电压香农熵; $p(w_h)$ 为弛豫电压。

2.2.2 弛豫电压曲线的最大曲率

弛豫电压曲线的最大曲率可以很好地量化描述曲线的形状特征,以及弛豫电压的最大弯曲程度。由于弛豫电压曲线形状与电池老化程度有关,因此分析弛豫电压曲线的最大曲率 U_r 与SOH的关系。

弛豫电压曲线的最大曲率 U_r 计算方法如下:

1) 计算弛豫电压曲线对时间的一阶导数 $D_1(\alpha)$,即

$$D_1(\alpha) = \frac{U(\alpha) - U(\alpha - 1)}{t(\alpha) - t(\alpha - 1)} \quad (4)$$

式中: $U(\alpha)$ 为第 α 个时间点的弛豫电压值; $t(\alpha)$ 为相应时间点的时间。

2) 将 $D_1(\alpha)$ 代入到下式计算弛豫电压曲率 $D_2(\alpha)$,即

$$D_2(\alpha) = \frac{D_1(\alpha) - D_1(\alpha - 1)}{t(\alpha) - t(\alpha - 1)} \quad (5)$$

3) 求 $D_2(\alpha)$ 的最大值,即为弛豫电压曲线的最大曲率 U_r 。

2.2.3 弛豫电压降序列偏度

弛豫电压降序列偏度 U'_{skr} 用于分析数据的分布特性,因此, U'_{skr} 可作为健康特征,其计算公式如下式所示:

$$U'_{skr} = \frac{(X_1 - \mu)^3 + (X_2 - \mu)^3 + \dots + (X_j - \mu)^3}{j \times \sigma^3} \quad (6)$$

式中: $X_1, X_2, \dots, X_j$ 为电压降序列中的每个电压值; μ 为电压降序列的均值; σ 为电压降序列的标准差; j 为电压值的总个数。

2.3 健康特征相关性分析与组合构建

为了提高SOH估计的准确性,将上述提取出的特征运用相关性分析方法,分析其与SOH的相

关性。采用 Pearson 相关系数来衡量特征与 SOH 之间的线性相关性强度和方向。

Pearson 相关系数的计算公式如下:

$$\rho = \frac{\sum_{a=1}^u (F_a - \bar{F})(SOH_a - \overline{SOH})}{\sqrt{\sum_{a=1}^u (F_a - \bar{F})^2} \sqrt{\sum_{a=1}^u (SOH_a - \overline{SOH})^2}} \quad (7)$$

式中: $\bar{F}$ 为健康特征的平均值; F_a 为健康特征的第 a 个样本值; SOH_a 为健康状态的第 a 个样本值; u 为样本数。

本文采用 NCA+NCM-CY25-0.5/4 的 #77 号电池进行 Pearson 相关系数实验。为了分析恒压充电阶段区间划分数量对相关性的影响,将电流区间数量 n 分别设置为 4, 6, 8 段,得到最后一个区间的时长分别为 t_{44} , t_{66} , t_{88} , 并与整段恒压充电时长 T_{cv} 一起进行对比。恒压充电特征与弛豫阶段特征与 SOH 的 Pearson 相关系数如表 2 所示;同时,给出各特征与 SOH 的关系图如图 2 所示。可见特征 T_{cv} , t_{44} , t_{66} , t_{88} , U'_{skr} 与 SOH 呈负相关关系,




图2 各特征与SOH关系图

Fig.2 Relationship between features and SOH

U_{sha} , U_r 与 SOH 呈正相关关系。

表2 特征变量的 Pearson 相关程度

Tab.2 Pearson correlation degree of the characteristic variable

特征名称	Pearson 相关系数	特征名称	Pearson 相关系数
T_{cv}	-0.99	U_{sha}	0.99
t_{44}	-0.99	U_r	0.96
t_{66}	-0.99	U'_{skr}	-0.36
t_{88}	-0.99		

根据 Pearson 相关系数的定义, ρ 的绝对值越大说明相关性越强。由表 2 可知, 4 个恒压充电阶段特征, 即 T_{cv} , t_{44} , t_{66} 与 t_{88} , 其 Pearson 相关系数的绝对值十分接近, 均在 0.99 以上, 因此均作为恒压充电阶段的候选特征, 并通过后续的实验对比来最终选定。表 2 中弛豫阶段特征 U_{sha} 与 U_r 的 Pearson 相关系数绝对值均大于 0.96, 相比 U'_{skr} 有更明显的相关性, 因此, 将 U_{sha} , U_r 作为弛豫阶段的健康特征。

3 基于两阶段充电数据融合的 SOH 估计方法

3.1 基于随机森林的 SOH 估计模型

随机森林是一种由决策树构成的并行集成模型。基于随机森林的 SOH 估计模型如下:

$$y_{RF} = \frac{1}{m} \sum_{\beta=1}^m u_{\beta} \quad (8)$$

式中: y_{RF} 为 SOH 估计结果; u_{β} 为第 β 棵决策树的回归结果; m 为决策树的数量。

随机森林通过使用决策树作为基学习器, 采用自助采样法生成每棵决策树的训练样本, 从而得到最优 SOH 估计结果, 其流程图如图 3 所示。具体步骤如下:

- 1) 给定原始电池数据集;
- 2) 对原始电池数据集进行可放回抽样。每次抽样均从原始电池数据集中随机抽取一个电池数据样本, 并将其放入各个样本电池数据集集合, 同时将该电池数据样本放回原始电池数据集集中;
- 3) 重复步骤 2), 生成 m 个样本电池数据集, 每个样本电池数据集包含 M 个电池数据样本;
- 4) 重复采样, 得到 m 个与原始电池数据集大小相同的样本电池数据集;
- 5) 得到 m 个决策树, 对 m 个决策树投票得出最优结果。

构建随机森林模型时, 采用有放回抽样方法

容易实现并行化,这使得随机森林在处理大规模数据集时能够高效运行,从而更迅速地完成 SOH 估计。该抽样方式引入了随机性与多样性,降低了模型在训练数据中噪声的影响,有效避免了过拟合,从而提高了 SOH 估计的准确性与可信度。




图3 随机森林流程图

Fig.3 Random forest regression flowchart

3.2 SOH 估计方法实施流程

基于随机森林的 SOH 估计流程如图 4 所示,具体步骤如下:

1)数据预处理。首先根据文献[27]给出的坏值范围过滤数据集的异常值,并将数据集进行标准化,使特征值落入均值为0、标准差为1的标准正态分布区间内。

2)模型超参数设置。本实验选取 NCA+NCM-CY25-0.5/1 的 #71 号、#72 号电池进行参数寻优。通过使用随机搜索方法寻找随机森林模型的最优超参数。

3)SOH 估计模型训练。利用寻找到的最优超参数对 SOH 估计模型进行训练。

4)SOH 估计结果输出。将特征组合输入到随机森林模型,SOH 作为输出。对输出的结果进行逆标准化,也就是将 SOH 预测结果从标准化后的值转换回原始数据的值。




图4 基于随机森林模型的SOH估计方法设计流程图

Fig.4 Design flowchart of SOH estimation method based on random forest regression model

4 实验结果与分析

4.1 评价指标

本模型采用绝对误差(mean absolute error, MAE)的平均值、预测值与真实值平方后求和的平均值(mean squared error, MSE)和模型能够解释数据方差的比例(R^2)作为评价指标来衡量 SOH 估计精度。

MAE 和 MSE 取值范围均为 $[0, +\infty]$,并且都是取值越小,模型越精确,具体计算如下:

$$MAE = \frac{1}{\varepsilon} \sum_{\delta=1}^{\varepsilon} |(y_{\delta} - \hat{y}_{\delta})| \times 100\% \quad (9)$$

$$MSE = \frac{1}{\varepsilon} \sum_{\delta=1}^{\varepsilon} (y_{\delta} - \hat{y}_{\delta})^2 \times 100\% \quad (10)$$

式中: ε 为样本数; y_{δ} 为电池最大可用容量真实值; $\hat{y}_{\delta}$ 为电池最大可用容量预测值。

R^2 的取值范围为 $[0, 1]$,一般来说, R^2 越大,表示模型拟合效果越好,具体计算如下:

$$R^2 = 1 - \frac{\sum_{\delta=1}^{\varepsilon} (\hat{y}_{\delta} - y_{\delta})^2}{\sum_{\delta=1}^{\varepsilon} (\bar{y}_{\delta} - y_{\delta})^2} \quad (11)$$

式中: $\bar{y}_{\delta}$ 为电池最大可用容量平均值。

4.2 实验设计

实验随机选取 3 个数据集 NCA, NCM, NCA+NCM 中的 5 个工况进行训练和测试,设定训练电池数量与测试电池数量的比例为 1:1。表 3 列出了不同实验工况下所对应的训练和测试电池。

表3 实验电池分配表

Tab.3 Experimental cell allocation

工况	对应实验工况代号	训练电池	测试电池
工况 1	NCA-CY45-0.5/1	#43, #44, #45, #46, #47, #48, #51, #52, #53, #54, #65, #66	#49, #50, #55, #56, #57, #58, #59, #60, #61, #62, #63, #64
工况 2	NCA-CY25-1/1	#1, #3, #9, #8	#2, #4, #5, #7
工况 3	NCM-CY35-0.5/1	#52, #53	#54, #55
工况 4	NCM-CY45-0.5/1	#1, #2, #6, #7, #12, #13, #16, #17, #18, #19, #21, #23, #24, #27	#3, #4, #5, #8, #9, #11, #10, #14, #15, #20, #22, #25, #26, #28
工况 5	NCA+NCM-CY25-0.5/4	#79	#78

4.3 恒压充电阶段特征选择实验

为对比分析恒压充电阶段候选特征 T_{cv} , t_{44} , t_{66} , t_{88} 对 SOH 估计效果的影响,从而获得最优特

征组合,通过将所述4个候选特征分别与 U_{sha}, U_r 组合来构建如表4所示的4种候选特征组合。

考虑到不同特征组合在获得最优估计效果时所对应的参数存在差异,为了使所有的特征组合都获得最优效果,利用随机搜索方法搜索每种候选特征组合的最优超参数,结果如表4所示。其中,决策树数量表示为 E_n ,每个决策树使用的特征数量表示为 F_{max} ,决策树的最大深度表示为 D_{max} ,叶子节点所需的最小样本数表示为 L_{min} 。

对于所提出的4种候选特征组合,分别利用随机森林模型进行SOH估计,表5给出了各工况下的估计误差。由表5可知,使用 $[t_{66}, U_{sha}, U_r]$ 构建SOH估计模型时,在大部分工况中的估计精度

表4 采用不同恒压特征组合的实验模型参数设置

Tab.4 Parameter settings of experimental models using different combinations of constant features

特征组合	E_n	F_{max}	D_{max}	L_{min}
$[T_{cv}, U_{sha}, U_r]$	20	auto	5	4
$[t_{44}, U_{sha}, U_r]$	10	auto	25	5
$[t_{66}, U_{sha}, U_r]$	50	auto	5	7
$[t_{88}, U_{sha}, U_r]$	10	sqrt	20	7

较为稳定,而且在所有工况下的平均MAE与平均MSE最小,并且平均 R^2 达到0.97。因此,最终选取 $[t_{66}, U_{sha}, U_r]$ 作为构建基于两阶段充电数据融合的SOH估计模型的健康特征组合。

表5 4种候选特征组合在各工况下的SOH估计结果

Tab.5 SOH estimation results for four candidate feature combinations for each operating condition

工况	$[T_{cv}, U_{sha}, U_r]$			$[t_{44}, U_{sha}, U_r]$			$[t_{66}, U_{sha}, U_r]$			$[t_{88}, U_{sha}, U_r]$		
	MAE/%	MSE/%	R^2	MAE/%	MSE/%	R^2	MAE/%	MSE/%	R^2	MAE/%	MSE/%	R^2
工况1	0.87	1.31	0.96	0.73	0.88	0.97	0.74	0.89	0.97	0.65	0.68	0.98
工况2	1.21	2.44	0.92	1.14	2.20	0.93	1.10	1.90	0.94	1.76	5.43	0.83
工况3	0.85	1.17	0.95	0.65	0.69	0.97	0.45	0.42	0.98	0.51	0.51	0.98
工况4	0.65	0.79	0.98	0.70	0.98	0.97	0.60	0.75	0.98	0.59	0.67	0.98
工况5	0.38	0.29	0.99	0.44	0.38	0.99	0.39	0.29	0.99	0.58	0.51	0.99
平均值	0.79	1.18	0.96	0.73	1.04	0.97	0.66	0.85	0.97	0.81	1.55	0.95

4.4 与单一阶段特征组合的实验对比

为证明所提特征组合的SOH估计效果,将本文所提特征组合与弛豫阶段特征组合、恒压充电阶段特征组合进行对比。弛豫特征组合采用文献[27]提出的弛豫电压方差、偏度和最大值组成的 $[U_{var}, U'_{skr}, U_{max}]$;恒压充电特征组合采用文献[31]提出的 $[t_{43}, t_{61}, t_{65}]$,其中, t_{43} 表示电流区间数量 n 为4时,取第3个区间时长; t_{61}, t_{65} 分别表示电流区间数量 n 为6时,取第1个、第5个区间时长。将上述3种特征组合分别输入SOH估计模型中,对比输出的SOH估计结果。

4.4.1 实验参数设置

在本小节中,利用随机搜索方法分别对使用弛豫特征组合、恒压充电特征组合作为输入的随机森林SOH估计模型进行最优超参数搜索,结果如表6所示,与单一阶段特征相比各工况条件下SOH估计结果如表7所示。

表6 单一阶段特征组合的实验模型参数设置

Tab.6 Parameter settings for combinations of single-stage feature combinations

特征组合	E_n	F_{max}	D_{max}	L_{min}
$[U_{var}, U'_{skr}, U_{max}]$	40	auto	5	4
$[t_{43}, t_{61}, t_{65}]$	60	sqrt	20	8

表7 与单一阶段特征相比各工况条件下SOH估计结果

Tab.7 SOH estimation results for each operating condition compared to single-stage feature combinations

工况	$[t_{66}, U_{sha}, U_r]$			$[U_{var}, U'_{skr}, U_{max}]^{[27]}$			$[t_{43}, t_{61}, t_{65}]^{[31]}$		
	MAE/%	MSE/%	R^2	MAE/%	MSE/%	R^2	MAE/%	MSE/%	R^2
工况1	0.74	0.89	0.97	1.01	1.77	0.95	1.52	4.25	0.89
工况2	1.10	1.90	0.94	2.44	10.16	0.69	2.54	10.92	0.66
工况3	0.45	0.42	0.98	0.47	0.35	0.98	0.84	1.02	0.96
工况4	0.61	0.75	0.98	0.62	0.61	0.98	0.69	0.88	0.98
工况5	0.39	0.29	0.99	0.89	1.22	0.99	0.58	0.72	0.99
平均值	0.66	0.85	0.97	1.08	2.80	0.92	1.23	3.56	0.90

4.4.2 实验结果对比

1) NCA数据集的实验结果。NCA数据集对应工况1、工况2,在该数据集的实验结果见表7。图5给出了模型在工况1、工况2下SOH估计结果的散点分布图,对应估计结果见表7。可见,在工况1下,与单一阶段的特征组合相比,所提特征组合的SOH估计结果具有更小的MAE和MSE,且SOH估计结果的对应点紧密分布在真实SOH曲线附近。在工况2下,两种单一阶段特征组合的估计误差也都明显大于本文所提的两阶段特征组合,且估计结果的对应点也更为分散。

2) NCM数据集的实验结果。NCM数据集对应工况3、工况4。图6为工况3、工况4下,3种特征组合的SOH估计结果的散点分布图,对应估计结果见表7。由实验结果可见,在工况3、工况4下,与单一阶段特征组合相比,本文所提特征组合的SOH估计结果对应点更加集中分布在真实SOH曲线两侧,估计误差均在较低的水平,表明所提特征组合具有更高的估计精度。

3) NCA+NCM数据集的实验结果。NCA+NCM数据集对应工况5。图7展示了工况5下SOH估计结果的散点分布图,工况5下的SOH估计结果




图5 NCA数据集的SOH估计结果散点分布图

Fig.5 Scatterplot of SOH estimation results for the NCA dataset




图6 NCM数据集的SOH估计结果散点分布图

Fig.6 Scatterplot of SOH estimation results for the NCM dataset




图7 NCA+NCM数据集的SOH估计结果散点分布图

Fig.7 Scatterplot of SOH estimation results for the NCA+NCM dataset

见表7。可见,利用所提特征的SOH估计结果的对应点高度集中在真实SOH曲线附近,MAE和MSE均小于0.4%;驰豫特征组合的SOH估计结果对应点在低SOH时分布较为分散;恒压充电阶段特征组合SOH估计结果的对应点在低SOH时分布在真实SOH曲线下。可见,对于NCA+NCM数据集,利用所提特征进行SOH估计,与单一阶段特征组合相比也具有较大的优势。

5 结论

本文提出了一种基于两阶段充电数据融合的储能系统锂离子电池SOH估计方法。通过融合恒压充电阶段与驰豫阶段的健康特征,构建了一种新的健康特征组合,充分挖掘两个阶段充电数据包含的电池老化信息,提高了SOH估计精度。针对恒压充电阶段,只采用其最后1/6区间的时长作为特征,无需保存电流数据,减少了数据存储和计算任务。同时,所提特征组合的获取不受充电起始点不确定性的影响,能够适应储能系统实际运行场景。实验结果表明,基于本文所提出的健康特征组合,所取得SOH估计结果的MAE平均值为0.66%,MSE平均值为0.85%, R^2 平均值为0.97,估计精度明显高于单一阶段特征组合。后续研究将在本文所提出的特征组合的基础上,探索结合深度学习模型的SOH估计方法,进一步提高估计精度。

参考文献

- [1] 马菁,段志勇,孙勇飞,等. 基于热管的储能锂电池散热特性数值模拟研究[J]. 中国电机工程学报, 2023, 43(17): 6737-6745.
MA Jing, DUAN Zhiyong, SUN Yongfei, et al. Numerical simulation on the heat dissipation characteristics of lithium battery for energy storage based on heat pipe[J]. Proceedings of the CSEE, 2023, 43(17): 6737-6745.
- [2] 王怡,陈学兵,王愿习,等. 储能锂离子电池多层级失效机理及分析技术综述[J]. 储能科学与技术, 2023, 12(7): 2079-2094.
- [3] 叶剑晓,于春梅,梁奇. 电动汽车用锂电池快速充电技术研究[J]. 电气传动, 2018, 48(6): 93-96.
YE Jianxiao, YU Chunmei, LIANG Qi. Research on quick charging technology for electric vehicle lithium battery[J]. Electric Drive, 2018, 48(6): 93-96.
- [4] CAI Lei, MENG Jinhao, STROE Daniel-loan I, et al. Multiobjective optimization of data-driven model for lithium-ion battery SOH estimation with short-term feature[J]. IEEE Transactions on Power Electronics, 2020, 35(11): 11855-11864.
- [5] QIN Taichun, ZENG Shengkui, GUO Jianbin. Robust prognostics for state of health estimation of lithium-ion batteries based on an improved PSO-SVR model[J]. Microelectronics Reliability, 2015, 55(9): 1280-1284.
- [6] GUO Yongfang, HUANG Kai, YU Xiangyuan, et al. State-of-health estimation for lithium-ion batteries based on historical dependency of charging data and ensemble SVR[J]. Electrochimica Acta, 2022, 428: 140940.
- [7] WU Tiezhou, HUANG Yiheng, XU Yuhong, et al. SOH prediction for lithium-ion battery based on improved support vector regression[J]. International Journal of Green Energy, 2023, 20(3): 227-236.
- [8] 魏业文,解园琳,李梅. 基于多指标最优权值融合的锂电池SOH估计[J]. 电子测量技术, 2021, 44(15): 23-29.
WEI Yewen, XIE Yuanlin, LI Mei. Estimation for state of health of lithium-ion batteries based on multi index optimal weight fusion[J]. Electronic Measurement Technology, 2021, 44(15): 23-29.
- [9] 陈琳,刘博豪,丁云辉,等. 采用粒子群优化和高斯回归实现电池SOH估计[J]. 汽车工程, 2021, 43(10): 1472-1478.
CHEN Lin, LIU Bohao, DING Yunhui, et al. Estimation of battery state-of-health using particle swarm optimization with gauss process regression[J]. Automotive Engineering, 2021, 43(10): 1472-1478.
- [10] 丁一,刘盛终,王旭东,等. 混沌粒子群算法-高斯过程回归的SOH估计[J]. 电气传动, 2022, 52(10): 70-75.

- DING Yi, LIU Shengzhong, WANG Xudong et al. SOH estimation of gaussian process regression based on chaotic particle swarm optimization[J]. *Electric Drive*, 2022, 52(10): 70–75.
- [11] LI Fang, MIN Yongjun, WANG Chen, et al. State of health estimation and remaining useful life predication of lithium batteries using charging process[J]. *Energy Storage Science and Technology*, 2022, 11(10): 3316.
- [12] 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.
- [13] WU Yitao, XUE Qiao, SHEN Jiangwei, et al. State of health estimation for lithium-ion batteries based on healthy features and long short-term memory[J]. *IEEE Access*, 2020, 8: 28533–28547.
- [14] SON Seho, JEONG Siheon, KWAK Eunji, et al. Integrated framework for SOH estimation of lithium-ion batteries using multiphysics features[J]. *Energy*, 2022, 238: 121712.
- [15] MA Yan, SHAN Ce, GAO Jinwu, et al. A novel method for state of health estimation of lithium-ion batteries based on improved LSTM and health indicators extraction[J]. *Energy*, 2022, 251: 123973.
- [16] YU Zhilong, LIU Na, ZHANG Yekai, et al. Battery SOH prediction based on multi-dimensional health indicators[J]. *Batteries*, 2023, 9(2): 80.
- [17] ZHANG Lijun, JI Tuo, YU Shihao, et al. Accurate prediction approach of SOH for lithium-ion batteries based on LSTM method[J]. *Batteries*, 2023, 9(3): 177.
- [18] 尹春杰, 王亚男, 李鹏飞, 等. 基于 LSTM 的储能蓄电池 SOC 与 SOH 联合在线估计[J]. *电源技术*, 2022, 46(5): 541–544.
- YIN Chunjie, WANG Yanan, LI Pengfei, et al. Joint online estimation of SOC and SOH of energy storage battery pack based on LSTM[J]. *Chinese Journal of Power Sources*, 2022, 46(5): 541–544.
- [19] SONG Shuxiang, CHEN Fei, XIA Haiying. Lithium-ion battery SOH estimation based on XGBoost algorithm with accuracy correction[J]. *Energies*, 2020, 13(4): 812.
- [20] ZHANG Mei, CHEN Wanli, YIN Jun, et al. Lithium battery health factor extraction based on improved douglas-peucker algorithm and SOH prediction based on XGboost[J]. *Energies*, 2022, 15(16): 5981.
- [21] 田野, 闵锦涛. 基于 PSO-XGBoost 算法的多衰退特征锂离子电池 SOH 估计[J]. *电工材料*, 2023(1): 23–27.
- TIAN Ye, MIN Jintao. SOH prediction of lithium ion battery with multiple degradation characteristics based on PSO-XG-Boost algorithm[J]. *Electrical Engineering Materials*, 2023(1): 23–27.
- [22] ZHANG Hao, GAO Jingyi, KANG Le, et al. State of health estimation of lithium-ion batteries based on modified flower pollination algorithm-temporal convolutional network[J]. *Energy*, 2023, 283: 128742.
- [23] JIANG Bo, ZHU Yuli, ZHU Jiangong, et al. An adaptive capacity estimation approach for lithium-ion battery using 10-min relaxation voltage within high state of charge range[J]. *Energy*, 2023, 263: 125802.
- [24] LIU Gengfeng, ZHANG Xiangwen, LIU Zhiming. State of health estimation of power batteries based on multi-feature fusion models using stacking algorithm[J]. *Energy*, 2022, 259: 124851.
- [25] ZHANG Chaolong, LUO Laijin, YANG Zhong, et al. Battery SOH estimation method based on gradual decreasing current, double correlation analysis and GRU[J]. *Green Energy and Intelligent Transportation*, 2023, 2(5): 100108.
- [26] ZHANG Qi, WANG Dafang, SCHIALTZ Erik, et al. Degradation mechanism analysis and state-of-health estimation for lithium-ion batteries based on distribution of relaxation times[J]. *Journal of Energy Storage*, 2022, 55: 105386.
- [27] ZHU Jiangong, 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.
- [28] GUO Peiyao, CHENG Ze, YANG Lei. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction[J]. *Journal of Power Sources*, 2019, 412: 442–450.
- [29] XIA Zhiyong, ABU QAHOUQ Jaber A. Lithium-ion battery ageing behavior pattern characterization and state-of-health estimation using data-driven method[J]. *IEEE Access*, 2021, 9: 98287–98304.
- [30] RÉNYI Alfréd. On measures of entropy and information[C]//Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Contributions to the Theory of Statistics. University of California Press, 1961, 4: 547–562.
- [31] PAN Wenjie, CHEN Qi, ZHU Maotao, et al. A data-driven fuzzy information granulation approach for battery state of health forecasting[J]. *Journal of Power Sources*, 2020, 475: 228716.

收稿日期: 2023–11–28

修改稿日期: 2023–12–09