

DOI: 10.12158/j.2096-3203.2025.01.014

# 基于新型健康特征的锂电池健康状态快速估计方法

董晓红<sup>1</sup>, 董进波<sup>2</sup>, 王明深<sup>3</sup>, 曾飞<sup>3</sup>, 潘益<sup>3</sup>

(1. 河北工业大学电气工程学院, 天津 300130;

2. 河北工业大学人工智能与数据科学学院, 天津 300130;

3. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103)

**摘要:** 锂电池健康状态 (state of health, SOH) 的在线估计是锂电池管理系统中必不可少的一部分。大部分基于数据驱动的锂电池 SOH 估计方法由于计算量较大, 难以在锂电池管理系统微控制器中在线使用。因此, 文中提出基于新型健康特征的锂电池 SOH 快速估计方法。首先, 分析锂电池的充电数据, 基于已有的锂电池恒流充电过程的等压升时间 (time interval of an equal charging voltage difference, TIECVD) 健康特征, 构建一个同充电电压起点、同充电时间间隔的健康特征。其次, 文中提出基于新型健康特征和多元线性回归 (multiple linear regression, MLR) 的锂电池 SOH 快速估计方法。然后, 通过对牛津锂电池老化数据集和美国国家航空航天局锂电池随机使用数据集进行分析, 以 0.01 V 步长遍历恒流充电电压区间, 以皮尔逊相关系数最大为目标, 确定锂电池最优的起始电压。最后, 考虑不同充电时间间隔, 利用最小二乘 (ordinary least squares, OLS) 回归分析方法, 确定锂电池最优充电时间间隔参数。使用 2 个数据集划分的训练集建立 MLR 模型, 使用 2 个数据集划分的验证集对文中方法进行验证。实验结果表明, 文中基于新型健康特征方法可极大缩减计算量, 并且可以在保障预测精度的前提下实现锂电池 SOH 的快速估计。

**关键词:** 锂电池; 健康状态 (SOH) 估计; 新型健康特征; 数据驱动方法; 多元线性回归 (MLR); 充电电压数据片段

中图分类号: TM912

文献标志码: A

文章编号: 2096-3203(2025)01-0136-07

## 0 引言

随着“双碳”目标的提出和清洁能源的大力推广, 电动汽车得到快速发展, 2021 年全球汽车保有量已达到 1 650 万辆, 预计到 2030 年全球电动汽车销售份额将达到全球汽车销量的 22%, 2024 年—2025 年全国将继续推行免征新能源汽车购置税等政策, 推动其产业发展和广泛应用<sup>[1-6]</sup>。

新能源汽车迅猛发展的背后是作为其核心的锂电池技术的不断创新。然而, 在长时间的循环使用中, 锂电池不可避免地会面临性能和容量的衰退问题, 甚至可能引发火灾或交通事故<sup>[7]</sup>。锂电池安全问题已经得到广泛的讨论和研究, 包括锂电池状态估计<sup>[8-11]</sup>、故障诊断<sup>[12]</sup>、快速充电<sup>[13]</sup>、预热技术<sup>[14]</sup>、老化机制和预测<sup>[15]</sup>、寿命诊断<sup>[16-17]</sup>、热失控<sup>[18]</sup>、热管理<sup>[19-20]</sup>、锂电池均衡<sup>[21]</sup>等。锂电池作为电动汽车不可或缺的组成部分, 有必要对其老化的异常因素进行研究。锂电池健康状态 (state of health, SOH) 反映已使用的锂电池当前的存储和供应能量的能力。文中使用锂电池容量定义锂电池 SOH, 当锂电池供电可用容量降低至一定程度 (例如

可用容量降至供电总容量的 70%) 以下时判定锂电池达到截止使用寿命, 需要对其进行替换。因此, 需要评估锂电池 SOH 的退化程度, 以确保锂电池能够安全可靠地运行; 在其寿命达到临界点时作出提醒, 以避免事故的发生。

近年来, 许多锂电池 SOH 估算方法被提出, 数据驱动方法由于其不依赖于固定模型、具有高精度的优势, 受到了广大学者的关注<sup>[22-24]</sup>。此类方法通过锂电池历史数据建立某些特征同锂电池 SOH 之间的映射关系, 通过在线阶段观测或计算得到的这些特征量, 利用锂电池历史数据建立的模型获得锂电池 SOH。底层特征和建立模型的算法工具是决定此类方法性能和实用性的关键要素。文献 [25] 结合长短期记忆神经网络与支持向量模型, 弥补传统支持向量机对于锂电池充电时间序列描述的不足, 提升对锂电池 SOH 的预测性能; 文献 [26] 提取锂电池的平均电压、电压差和温度差等特征量, 基于极值梯度提升算法, 提出一种可将锂电池 SOH 估算误差控制在  $\pm 0.4\%$  的方法; 文献 [27] 将当前锂电池电压片段与锂电池刚使用时相应电压片段曲线的高斯核距离作为特征, 建立该特征与锂电池 SOH 间对应的映射关系, 实现模型的简化; 文献 [28] 基于锂电池的容量分析, 利用支持向量机建立 4 个特征与锂电池 SOH 之间的非线性函数模型; 文

收稿日期: 2024-05-19; 修回日期: 2024-07-28

基金项目: 国家自然科学基金资助项目 (52477101); 教育部“春晖计划”合作科研项目 (HZKY20220265)

献[29]提出将轻量梯度提升和类别梯度提升等集成学习方法融入长短期记忆网络,建立锂电池 SOH 实时预测模型,准确预测锂电池的性能衰减趋势。

智能算法使锂电池 SOH 估计准确度得到显著的提高。然而,这些智能算法普遍复杂性较高,特别是深度学习的算法模型中需要更好的中央处理器(central processing unit, CPU)、内存等计算资源,也导致这些智能算法的实际可应用性不高。此外,大多数算法通常使用完整的锂电池充放电数据,直接作为输入或用来提取二重特征,然后放入模型中进行训练。然而,在锂电池实际使用过程中,受人为和工作条件的影响,开始充电和终止充电时锂电池的荷电状态很难确定,因此获得的充电数据往往是片段且没有任何规律的。基于此,在不降低锂电池 SOH 估计准确性的前提之下,算法模型的简化与计算量的减少对于实际锂电池管理系统的实现非常关键。

综上所述,文中通过分析锂电池使用过程中充电电压曲线特性,基于已有的锂电池恒流充电过程的等压升时间(time interval of an equal charging voltage difference, TIECVD)<sup>[30]</sup>特征,构建一个新型健康特征,即同充电电压起点、同充电时间间隔的健康特征,也叫同区间电压差(voltage difference in the same interval, VDSI)健康特征,通过对该新型健康特征的分析,利用遍历法和普通最小二乘(ordinary least squares, OLS)回归分析法,确定锂电池最优的起始充电电压和最优充电时间间隔参数。文中提出基于多元线性回归(multiple linear regression, MLR)模型的锂电池 SOH 快速估计方法。

## 1 锂电池老化数据集介绍与分析

### 1.1 锂电池老化数据集介绍

文中采用牛津锂电池老化数据集<sup>[31]</sup>作为数据集 1,取 3/4 的锂电池数据进行训练,对提出的 VDSI 特征进行分析,剩下 1/4 的锂电池数据用于验证;采用美国国家航空航天局锂电池随机使用数据集<sup>[32]</sup>作为数据集 2,采用相同的比例划分对构建的 VDSI 特征和提出的锂电池 SOH 快速估计方法进行训练与验证。2 个数据集的技术参数见表 1。2 个数据集所用锂电池容量随循环次数的衰减曲线见图 1。其中,数据集 1 中 C5 锂电池在循环 4 400 次后容量突降,C2 锂电池在循环 6 800 次后亦有突降和大幅度波动的现象,该段数据无效,将该段数据去除。

### 1.2 锂电池老化数据集分析

从 2 个数据集中分别选出 1 个锂电池进行分

表 1 数据集详细技术参数

Table 1 Data set detailed technical parameters		
指标项目	数据集 1	数据集 2
锂电池类型	Kokam 软包锂电池	LG chem 18650 圆柱锂电池
数量	8(C1—C8)	4(低倍率)+4(高倍率) (R13—R20)
容量/(A·h)	0.74	2.1
实验温度/℃	40	室温
标准充放电	每 100 次循环	每 50 次循环
采样间隔/s	1	60
充放电方式	使用数据集 1 中工况进行充电,直至寿命结束(end of life, EOL)(80%SOH)	放电电流(-4.5,-3.75,-3,-2.25,-1.5,-0.75), 充电电流(1.5,2.25,3,3.75,4.5) (随机利用电流值进行充放电模拟)
采集内容	电压、温度、容量	时间、电压、温度、容量

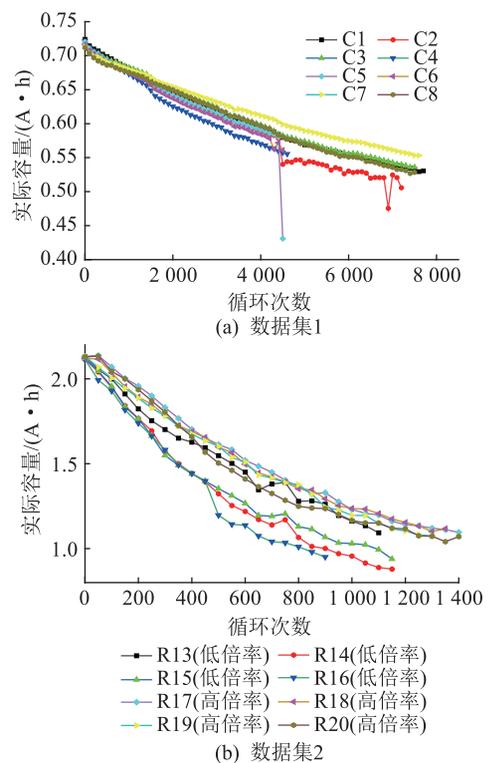


图 1 锂电池容量衰减曲线

Fig.1 Lithium battery capacity decline curves

析,将锂电池的当前最大容量与额定容量的比值定义为锂电池 SOH,不同 SOH 下锂电池充电电压随时间的变化情况如图 2 所示。充电电压曲线颜色变化为绿色→黄色→橙色→红色。由图 2 可知,锂电池充电电压曲线因采用标准的恒流-恒压(constant current-constant voltage, CC-CV)充电方式而相对稳定,且随着锂电池老化,其充电电压随时间的变化呈现一定规律性。具体表现为,锂电池使用时间较短,锂电池 SOH 良好时,即绿色曲线部分,恒流充电时间长,在 3 500 s 时充电完成,电压上升至截止电

压的速度较慢。而在锂电池使用一段时间,SOH 接近设定终止寿命时,即橙色和红色曲线部分,呈现的现象与新锂电池有所不同,在 2 700~3 100 s内电压很快上升至截止电压,此时锂电池的可用容量也随之减小。通过分析可知,截取充电电压曲线进行特征提取建立锂电池 SOH 估计模型的方法是可行的。

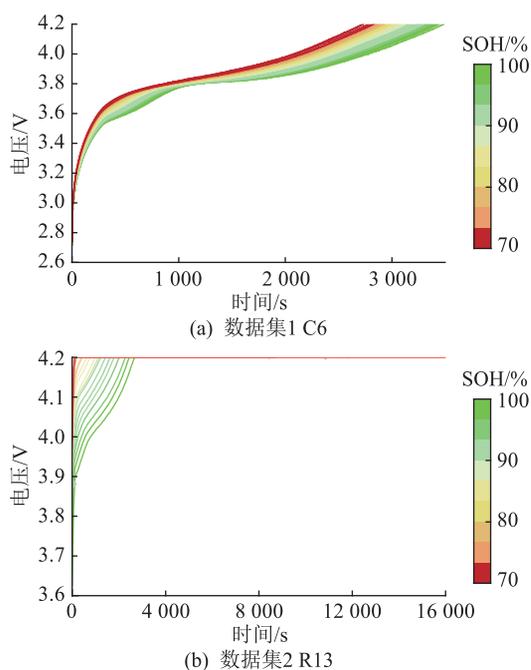


图2 不同 SOH 下锂电池充电电压变化情况  
Fig.2 Change of lithium battery charging voltage under different SOH

## 2 锂电池 SOH 快速估计方法与评估指标

### 2.1 新型健康特征与锂电池 SOH 快速估计方法

由图 2 可知,已有的健康特征——TIECVD 采用直接对锂电池的充电曲线进行特征获取,TIECVD 方法为选定充电电压区间,获取首尾电压采样时刻,得到充电时间间隔。新型健康特征 VDSI 方法为选定电压片段同起点,将某时间段之后的电压与起点电压的差值作为度量,即等充电时间间隔的电压差值。

VDSI 对充电电压采样点的定位采用与 TIECVD 相同的起始电压点,利用等时间间隔的电压差值代替其他需要进行深度挖掘或需要对电压曲线相应片段进行一系列映射计算,从而极大地减少计算量。

对 VDSI 与锂电池 SOH 之间的映射关系进行分析。选择合适的时间间隔,建立  $n$  个充电时间间隔特征与锂电池 SOH 之间的映射关系,得到训练样本  $D = \{((x_{11}, x_{12}, \dots, x_{1n}), (x_{21}, x_{22}, \dots, x_{2n}), \dots, (x_{i1}, x_{i2}, \dots, x_{in}), \dots, (x_{m1}, x_{m2}, \dots, x_{mn}))^T, (y_1, y_2, \dots,$

$y_i, \dots, y_m)^T\} = \{X, y\}$ ,其中  $X$  为  $m \times n$  阶特征矩阵,  $(x_{i1}, x_{i2}, \dots, x_{in})$  为第  $i$  条锂电池充电电压曲线在时间间隔为  $N(N = N_1, N_2, \dots, N_n)$  时的 VDSI 特征向量; $y$  为锂电池 SOH 列向量,其中  $y_i$  为第  $i$  条锂电池充电电压曲线对应的锂电池 SOH 实际值; $m$  为训练集中可用的充电电压曲线数。利用 MLR 模型,确定  $X$  与  $y$  之间的映射关系,即文中提出的基于新型健康特征和 MLR 的锂电池 SOH 快速估计方法。由于特征向量为 0 时没有实际意义,因此不设置常数项,具体如式(1)所示。

$$y \approx Xw \quad (1)$$

式中: $w$  为特征向量对应系数组成的列向量,可通过式(2)利用 OLS 法确定。

$$w = \arg \min \|y - Xw\|_2 \quad (2)$$

式中: $\|\cdot\|_2$  为向量的 2-范数。

基于新型健康特征 VDSI 和 MLR 的锂电池 SOH 快速估计方法求解流程如图 3 所示。



图3 基于新型健康特征 VDSI 和 MLR 的锂电池 SOH 估计方法流程

Fig.3 The lithium battery SOH estimation method flow chart based on the new health feature VDSI and MLR

### 2.2 评价指标

文中使用皮尔逊相关系数评价构建的健康特征与锂电池 SOH 之间的关系。皮尔逊相关系数常用于衡量 2 个随机变量之间的线性关系,其定义如下:

$$r = \frac{\text{Cov}(Z, Y)}{\sigma_Z \sigma_Y} \quad (3)$$

式中: $Z, Y$  分别为自变量和因变量; $\text{Cov}(Z, Y)$  为 2 个变量之间的协方差; $\sigma_Z, \sigma_Y$  为 2 个变量各自的标准差。皮尔逊相关系数  $r$  值在  $-1 \sim 1$  之间,绝对值越接近 1 表明两者线性相关性越强。

为了对提出的锂电池 SOH 快速估计方法的性能进行评估,并与已有的核岭回归(kernel ridge re-

gression, KRR)<sup>[27]</sup>方法相比较,使用平均绝对误差  $E_{\text{mae}}$  和最大误差  $E_{\text{max}}$  作为评价指标,如式(4)和式(5)所示。

$$E_{\text{mae}} = \frac{1}{m} \sum_{i=1}^m |y_i - y'_i| \quad (4)$$

$$E_{\text{max}} = \max |y_i - y'_i| \quad (5)$$

式中:  $y'_i$  为第  $i$  条锂电池充电电压曲线对应的 SOH 估计值。

### 3 锂电池 VDSI 分析优化及结果

#### 3.1 锂电池 VDSI 特征分析

使用数据集 1 进行分析,取出充电时间间隔相同的 8 个锂电池数据,其中 VDSI 与锂电池 SOH 之间的关系如图 4 所示。由图 4 可知,VDSI 与锂电池 SOH 之间呈现极强的负相关线性关系。随着锂电池 SOH 值减小,VDSI 增大,这与 1.2 节提到的随着锂电池使用,锂电池 SOH 值减小,恒流充电电压时间变短,充电电压增长变快的实际趋势一致。

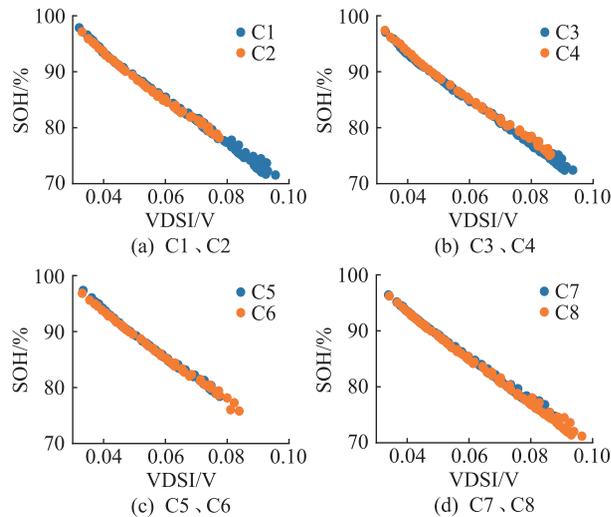


图 4 VDSI 与锂电池 SOH 之间的关系

Fig.4 Relationship between VDSI and lithium battery SOH

#### 3.2 参数优化

VDSI 由充电起始电压  $V_0$  和充电时间间隔  $N$  决定。因此这 2 个参数的选择是决定 VDSI 与锂电池 SOH 之间映射关系准确性的关键。选取  $n$  个充电时间间隔进行特征提取,将各充电时间间隔值内得到的  $n$  维健康特征量作为输入,与锂电池 SOH 值之间建立映射关系。

##### 3.2.1 充电起始电压 $V_0$

由图 2 可知,起始充电阶段电压增长迅速,且随着锂电池老化,起始充电部分电压曲线基本重合,因此得到的特征与锂电池 SOH 之间线性关系较差。

选定电压稳定增长的中间阶段,以 0.01 V 的电压间隔遍历该区间,选定电压稳定增长的中间阶段(总时间的 1/3,即 500 s)作为 VDSI 的时间间隔。优化目标为 VDSI 与锂电池 SOH 之间皮尔逊相关系数最大时对应的起始电压值。不同充电起始电压对应皮尔逊相关系数如图 5 所示。

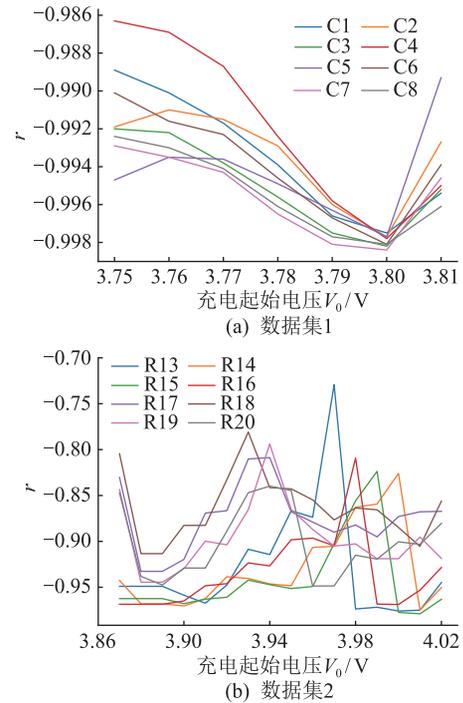


图 5 不同充电起始电压对应皮尔逊相关系数

Fig.5 Pearson correlation coefficient for different starting voltages

从图 5(a)可以看出,数据集 1 最优的充电起始电压值为 3.8 V。从图 5(b)可以看出,数据集 2 皮尔逊相关系数波动较大,对 8 个锂电池充电起始电压处的皮尔逊相关系数取平均值,结果如表 2 所示,可知数据集 2 的最优充电起始电压为 3.89 V。

表 2 数据集 2 充电起始电压对应皮尔逊相关系数平均值

Table 2 The starting voltage of data set 2 corresponds to the average Pearson correlation coefficient

充电起始电压 $V_0/V$	皮尔逊相关系数平均值	充电起始电压 $V_0/V$	皮尔逊相关系数平均值
3.87	-0.894	3.95	-0.885
3.88	-0.947	3.96	-0.899
3.89	-0.948	3.97	-0.883
3.90	-0.941	3.98	-0.883
3.91	-0.927	3.99	-0.903
3.92	-0.911	4.00	-0.915
3.93	-0.877	4.01	-0.932
3.94	-0.877	4.02	-0.896

##### 3.2.2 充电时间间隔 $N$

使用 OLS 进行回归分析,得到的调整后的线性

相关系数  $R_{adjusted}^2$ 、检验概率值  $P_{F-statistic}$  和各不同时间间隔特征与锂电池 SOH 线性关系的显著性检验概率值  $P$ 。 $R_{adjusted}^2$  和  $P_{F-statistic}$  表示整个 MLR 模型的拟合度;显著性检验概率值  $P$  表示各不同时间间隔特征值和锂电池 SOH 间是否具有显著线性相关性。选取合适的阈值,将  $P$  大于阈值的特征对应的时间间隔进行显著性优化,其优化原则为先去掉 1 个最大  $P$  值所对应的时间间隔,然后重新进行分析,直到所有的  $P$  都在阈值内,剩下线性关系较为显著的时间间隔对应的 VDSI 特征用来建模。

使用数据集 1 中数据进行 OLS 回归分析,共 490 条可用充电电压曲线数据。为避免起始电压点取到恒压曲线部分,将时间序列设为 100~1 000 s,每隔 100 s 进行取值,然后对相应的数据进行分析。

数据集 1 分析结果为  $R_{adjusted}^2 = 0.999$ 、 $P_{F-statistic} = 0$ ,各时间间隔下的  $P$  如表 3 所示。经考虑设置阈值为 0.05, $P$  大于阈值时表明其显著性不强。因此,经 OLS 分析后,最优的时间间隔为去除 300 s 和 500 s 的时间间隔序列。

表 3 数据集 1 OLS 分析结果

Table 3 Data set 1 OLS analysis results

时间间隔 N/s	$P$	时间间隔 N/s	$P$
100	0	600	0.034
200	0.006	700	0.002
300	0.143	800	0.019
400	0.001	900	0.008
500	0.007	1 000	0

使用数据集 2 中数据进行 OLS 回归分析,共 80 条可用充电电压曲线数据,选定  $V_0$  后,将时间序列设为 1~10 s,每隔 1 s 进行取值。

数据集 2 分析结果为  $R_{adjusted}^2 = 0.959$ 、 $P_{F-statistic} = 0$ ,各时间间隔下的  $P$  如表 4 所示。此次阈值选择 0.2,进行显著性优化。经过 OLS 分析得到,最优的时间间隔为去除 4、8、10 s 的时间间隔序列。利用 OLS 法分析结果进行 MLR 模型建模。

表 4 数据集 2 OLS 分析结果

Table 4 Data set 2 OLS analysis results

时间间隔 N/s	$P$	时间间隔 N/s	$P$
1	0.093	6	0.062
2	0.077	7	0.284
3	0.223	8	0.349
4	0.887	9	0.310
5	0.301	10	0.366

### 3.3 估计结果

文中选取与 KRR 方法中相同的锂电池数据,即

数据集 1 的 C4 和 C8 锂电池数据进行预测,其余数据对模型进行训练。选取数据集 2 中 R16 和 R20 锂电池数据进行预测,其余数据对模型进行训练。数据集 2 与 KRR 方法所用锂电池不同,因此将测试集中 C4 和 C8 的充电电压曲线及对应的健康状态数据设置为全局量,仅对全局量的评估结果进行比较。

数据集 1 中锂电池 SOH 估计结果如图 6 所示,文中提出的健康特征与 MLR 方法均取得了不错的锂电池 SOH 估计结果。数据集 1 中锂电池 SOH 评价指标如表 5 所示。与现有的 KRR 方法相比,MLR 方法不仅降低算法复杂度,减少一半估计时间,即提升一倍估计速度,而且准确度并没有降低,满足目前锂电池管理系统的需求。

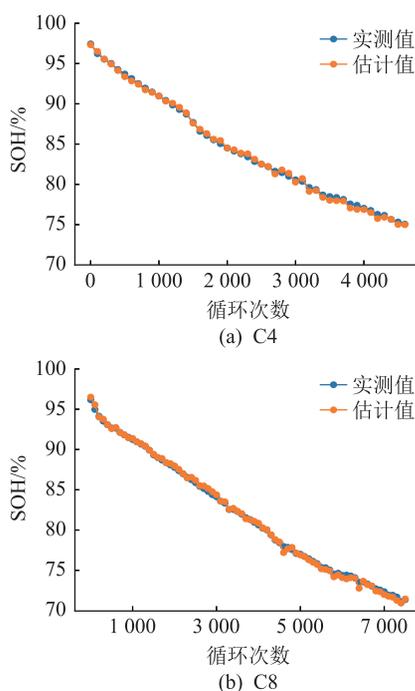


图 6 数据集 1 锂电池 SOH 估计结果

Fig.6 Data set 1 lithium battery SOH estimation results

表 5 数据集 1 锂电池 SOH 评价指标

Table 5 Data set 1 evaluating indicator of lithium battery SOH

方法	C4		C8		全局量		时间/s
	$E_{mae}/\%$	$E_{max}/\%$	$E_{mae}/\%$	$E_{max}/\%$	$E_{mae}/\%$	$E_{max}/\%$	
KRR	0.21	0.51	0.25	0.76	0.23	0.76	15
MLR	0.23	0.53	0.17	0.77	0.20	0.77	4

数据集 2 中锂电池 SOH 估计结果如图 7 所示,对于数据集 2 来说,在锂电池数据采样间隔较大的情况下,文中提出的锂电池 SOH 快速估计方法依然得到了良好的运行结果。数据集 2 中锂电池 SOH 评价指标如表 6 所示,MLR 方法与 KRR 方法相比,

不仅在估计时间上得到很大缩减,准确度亦得到提高,表明文中所提方法具有强大的泛化能力。

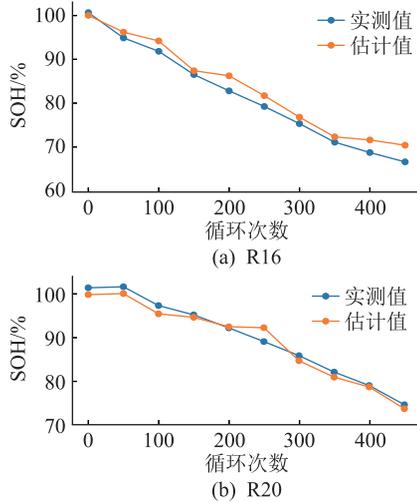


图7 数据集2锂电池SOH估计结果

Fig.7 Data set 2 lithium battery SOH estimation results

表6 数据集2锂电池SOH评价指标

Table 6 Data set 2 evaluating indicator of lithium battery SOH

方法	全局量		时间/s
	$E_{mac}/\%$	$E_{max}/\%$	
KRR	2.29	7.73	8
MLR	1.65	3.80	3

## 4 结论

文中针对锂电池的实际使用工况,构建了一个锂电池新型健康特征——VDSI,提出基于该特征和MLR的锂电池SOH快速估计方法。经2个权威公开数据集的验证,得到结论如下:(1)该方法不仅可以保证锂电池SOH估计结果的精度,且估计时间在5s以内,比KRR方法用时缩减一半,可满足锂电池SOH在线估计需求。(2)该方法占用计算资源较少,可实现在锂电池管理系统微控制器上的快速准确SOH估计,为实时锂电池管理提供参考。

文中所提方法也存在不足,其过于依赖稳定的充电条件,在现实情况例如锂电池充电时的温度无法保持恒定,温度的波动会导致充电电压曲线出现细微波动。因此,后续研究可以考虑引入温度校正系数,对充电电压加以校正,得到更加精确的锂电池SOH估计。

### 参考文献:

[1] 李达,冯景丽,平健,等. 基于双层区块链的电动汽车充电隐私数据可信聚合方法[J]. 电力建设,2023,44(11):13-22.  
LI Da, FENG Jingli, PING Jian, et al. Rustworthy aggregation method of electric vehicle charging private data based on dou-

ble-layer blockchain[J]. Electric Power Construction, 2023, 44(11):13-22.

- [2] 张夏韦,梁军,王要强,等. 电动汽车充电负荷时空分布预测研究综述[J]. 电力建设,2023,44(12):161-173.  
ZHANG Xiawei, LIANG Jun, WANG Yaoqiang, et al. Overview of research on spatiotemporal distribution prediction of electric vehicle charging [J]. Electric Power Construction, 2023, 44(12):161-173.
- [3] 王镇林,陈麒宇,张雅静,等. 基于混合储能减小平抑功率滞后性的风电平抑策略[J]. 电力建设,2023,44(9):149-159.  
WANG Zhenlin, CHEN Qiyu, ZHANG Yajing, et al. Wind-power smoothing strategy based on hybrid energy storage to reduce smoothing power lag [J]. Electric Power Construction, 2023, 44(9):149-159.
- [4] 尚龙龙,程俊杰,王伟,等. 计及交通拥堵的电动汽车充电站规划方法[J]. 电力科学与技术学报,2023,38(1):66-76.  
SHANG Longlong, CHENG Junjie, WANG Wei, et al. An electric vehicle charging station planning method considering traffic congestion [J]. Journal of Electric Power Science and Technology, 2023, 38(1):66-76.
- [5] 叶文浩,陈耀红,颜勤,等. 基于动态分时电价引导的电动汽车需求侧响应[J]. 电力科学与技术学报,2024,39(4):138-145.  
YE Wenhao, CHEN Yaohong, YAN Qin, et al. Demand response of electric vehicle based on dynamic time-to-use electricity price [J]. Journal of Electric Power Science and Technology, 2024, 39(4):138-145.
- [6] 周卓,芦翔,刘海涛,等. 含新能源发电的电动汽车充电站充电功率在线优化策略研究[J]. 电测与仪表,2024,61(2):101-107.  
ZHOU Zhuo, LU Xiang, LIU Haitao, et al. Research on on-line charging power optimization strategy for EV charging station with renewable energy generation [J]. Electrical Measurement & Instrumentation, 2024, 61(2):101-107.
- [7] 薄利明,郑惠萍,张世锋,等. 锂电池健康状态均衡技术综述[J]. 电测与仪表,2023,60(4):11-18.  
BO Liming, ZHENG Huiping, ZHANG Shifeng, et al. Review on health state equalization technology for lithium batteries [J]. Electrical Measurement & Instrumentation, 2023, 60(4):11-18.
- [8] WANG Y J, TIAN J Q, SUN Z D, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems [J]. Renewable and Sustainable Energy Reviews, 2020, 131:110015.
- [9] PARK S, AHN J, KANG T, et al. Review of state-of-the-art battery state estimation technologies for battery management systems of stationary energy storage systems [J]. Journal of Power Electronics, 2020, 20(6):1526-1540.
- [10] WANG C C, SU Y Y, YE J L, et al. Enhanced state-of-charge and state-of-health estimation of lithium-ion battery incorporating machine learning and swarm intelligence algorithm [J]. Journal of Energy Storage, 2024, 83:110755.
- [11] LIU F, YU D, SHAO C, et al. A review of multi-state joint esti-

- mation for lithium-ion battery; research status and suggestions [J]. *Journal of Energy Storage*, 2023, 73: 109071.
- [12] XIONG R, MA S X, LI H L, et al. Toward a safer battery management system; a critical review on diagnosis and prognosis of battery short circuit [J]. *iScience*, 2020, 23(4): 101010.
- [13] TOMASZEWSKA A, CHU Z Y, FENG X N, et al. Lithium-ion battery fast charging: a review [J]. *eTransportation*, 2019, 1: 100011.
- [14] HU X S, ZHENG Y S, HOWEY D A, et al. Battery warm-up methodologies at subzero temperatures for automotive applications: recent advances and perspectives [J]. *Progress in Energy and Combustion Science*, 2020, 77: 100806.
- [15] LIU K L, ASHWIN T R, HU X S, et al. An evaluation study of different modelling techniques for calendar ageing prediction of lithium-ion batteries [J]. *Renewable and Sustainable Energy Reviews*, 2020, 131: 110017.
- [16] HU X S, XU L, LIN X K, et al. Battery lifetime prognostics [J]. *Joule*, 2020, 4(2): 310-346.
- [17] 章枫, 房乐, 陆承宇, 等. 计及电池寿命的储能参与调频市场收益分析 [J]. *浙江电力*, 2021, 40(12): 61-68.  
ZHANG Feng, FANG Le, LU Chengyu, et al. Market returns analysis of energy storage participating in frequency regulation considering battery life [J]. *Zhejiang Electric Power*, 2021, 40(12): 61-68.
- [18] FENG X N, OUYANG M G, LIU X, et al. Thermal runaway mechanism of lithium ion battery for electric vehicles; a review [J]. *Energy Storage Materials*, 2018, 10: 246-267.
- [19] SIDDIQUE A R M, MAHMUD S, VAN HEYST B. A comprehensive review on a passive (phase change materials) and an active (thermoelectric cooler) battery thermal management system and their limitations [J]. *Journal of Power Sources*, 2018, 401: 224-237.
- [20] HWANG F S, CONFREY T, REIDY C, et al. Review of battery thermal management systems in electric vehicles [J]. *Renewable and Sustainable Energy Reviews*, 2024, 192: 114171.
- [21] FENG F, HU X S, LIU J F, et al. A review of equalization strategies for series battery packs: variables, objectives, and algorithms [J]. *Renewable and Sustainable Energy Reviews*, 2019, 116: 109464.
- [22] LI Y, LIU K L, FOLEY A M, et al. Data-driven health estimation and lifetime prediction of lithium-ion batteries; a review [J]. *Renewable and Sustainable Energy Reviews*, 2019, 113: 109254.
- [23] 刘昊天, 王萍, 程泽. 一种编解码器模型的锂离子电池健康状态估算 [J]. *中国电机工程学报*, 2021, 41(5): 1851-1859.  
LIU Haotian, WANG Ping, CHENG Ze. A novel method based on encoder-decoder framework for li-ion battery state of health estimation [J]. *Proceedings of the CSEE*, 2021, 41(5): 1851-1859.
- [24] 赵显赫, 耿光超, 林达, 等. 基于数据驱动的锂离子电池健康状态评估综述 [J]. *浙江电力*, 2021, 40(7): 65-73.  
ZHAO Xianhe, GENG Guangchao, LIN Da, et al. Review of data-driven state of health estimation for lithium-ion battery [J]. *Zhejiang Electric Power*, 2021, 40(7): 65-73.
- [25] 王宇胜, 陈德旺, 蔡俊鹏, 等. 基于 LSTM-SVR 的锂电池健康状态预测研究 [J]. *电源技术*, 2020, 44(12): 1784-1787.  
WANG Yusheng, CHEN Dewang, CAI Junpeng, et al. Research on lithium battery state of health prediction based on LSTM-SVR [J]. *Chinese Journal of Power Sources*, 2020, 44(12): 1784-1787.
- [26] 费陈, 赵亮, 王云恪, 等. 基于 XGBoost 算法的锂离子电池健康状态估算 [J]. *浙江电力*, 2022, 41(5): 14-21.  
FEI Chen, ZHAO Liang, WANG Yunke, et al. SOH estimation of li-ion battery based on XGBoost algorithm [J]. *Zhejiang Electric Power*, 2022, 41(5): 14-21.
- [27] 樊亚翔, 肖飞, 许杰, 等. 基于充电电压片段和核岭回归的锂离子电池 SOH 估计 [J]. *中国电机工程学报*, 2021, 41(16): 5661-5669.  
FAN Yaxiang, XIAO Fei, XU Jie, et al. State of health estimation of lithium-ion batteries based on the partial charging voltage segment and kernel ridge regression [J]. *Proceedings of the CSEE*, 2021, 41(16): 5661-5669.
- [28] LI L F, CUI W W, HU X, et al. A state-of-health estimation method of lithium-ion batteries using ICA and SVM [C]//2021 Global Reliability and Prognostics and Health Management (PHM-Nanjing). Nanjing, China. IEEE, 2021: 1-5.
- [29] 刘伟霞, 田勋, 肖家勇, 等. 基于混合模型及 LSTM 的锂电池 SOH 与剩余寿命预测 [J]. *储能科学与技术*, 2021, 10(2): 689-694.  
LIU Weixia, TIAN Xun, XIAO Jiayong, et al. Estimation of SOH and remaining life of lithium batteries based on a combination model and long short-term memory [J]. *Energy Storage Science and Technology*, 2021, 10(2): 689-694.
- [30] YAO F, HE W X, WU Y X, et al. Remaining useful life prediction of lithium-ion batteries using a hybrid model [J]. *Energy*, 2022, 248: 123622.
- [31] BIRKL C. Oxford battery degradation dataset 1 [M]. Massachusetts University of Oxford press, 2017.
- [32] BOLE B, KULKARNI C S, DAIGLE M. Adaptation of an electrochemistry-based li-ion battery model to account for deterioration observed under randomized use [C]//Proceedings of Annual Conference of the Prognostics and Health Management Society. Fort Worth, TX, USA, 2014.

作者简介:



董晓红

董晓红(1989),女,博士,讲师,研究方向为电力系统与交通融合技术(E-mail: dxh@hebut.edu.cn);

董进波(1998),男,硕士在读,研究方向为智慧能源与智能控制;

王明深(1990),男,博士,工程师,从事电动汽车入网与优化调控、电力需求侧资源响应控制技术等相关工作。

(下转第 206 页)

## Cooperative game scheduling and revenue sharing strategy for virtual power plants considering scenery uncertainty

SONG Duoyang, XUE Tianliang, LI Yipu, TU Jintong, BI Yuhao, WANG Mankang

(College of Electricity and New Energy, Three Gorges University, Yichang 443000, China)

**Abstract:** Virtual power plants (VPP) efficiently aggregate small-capacity and large-volume distributed energy resources through advanced control technologies to participate in electricity market transactions. With the increase in the number of distributed energy sources, the volatility of their power output and the problem of their returns after aggregation still need to be solved. Based on this, a cooperative game scheduling model is proposed for multi-type distributed energy sources aggregated in a virtual power plant under the day-ahead power market. Firstly, the operation framework of multi-type distributed energy aggregation in virtual power plant is proposed. Then, a combined prediction model based on variational modal decomposition (VMD) and improved bidirectional multi gated long short-term memory (Bi-MGLSTM) network is established because the uncertainty of wind power output seriously affects the operation of the system. Secondly, the same type of distributed energy sources form alliances and aim to maximize the revenue from power sales, and construct a cooperative game scheduling model for multiple alliances of virtual power plants. In order to realize the fairness of revenue distribution among alliances and members, a multifactor improvement shapley value method and a two-stage refinement of the revenue distribution scheme based on the parity cycle kernel method are designed. Finally, the example results show that the proposed method effectively improves the prediction accuracy of wind power, realizes the cooperative and complementary operation among alliances within the virtual power plant, and ensures the fairness and reasonableness of the revenue distribution among multiple subjects.

**Keywords:** virtual power plant (VPP); distributed energy resource (DER); wind and solar forecasting; cooperative gaming; shapley values; kernel method

(编辑 方晶)

(上接第 142 页)

## Rapid estimation method of lithium battery state of health based on novel health feature

DONG Xiaohong<sup>1</sup>, DONG Jinbo<sup>2</sup>, WANG Mingshen<sup>3</sup>, ZENG Fei<sup>3</sup>, PAN Yi<sup>3</sup>

(1. School of Electrical Engineering, Hebei University of Technology, Tianjin 300130, China;

2. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300130, China;

3. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China)

**Abstract:** The online estimation of the state of health (SOH) is an essential part of a lithium battery management system. Most data-driven lithium battery SOH estimation methods are computationally intensive and difficult to use in real-time in battery management system microcontrollers. Therefore, a rapid estimation method of lithium battery SOH based on novel health feature is proposed in this paper. The charging data of the battery is firstly analyzed in the method, and based on the existing health characteristics of time interval of an equal charging voltage difference (TIECVD) in the constant current charging process of the battery, constructs a new health feature, that is, the health feature of charging voltage at the same starting point and charging time interval. Then, a fast estimation method of lithium battery SOH based on the novel health feature and multiple linear regression (MLR) is proposed. Next, by analyzing the oxford battery aging dataset and the random usage dataset of lithium ion batteries used by NASA, the method traverses the constant current charging voltage range in steps of 0.01 V and determines the optimal starting voltage of the lithium battery by maximizing the Pearson correlation coefficient. Finally, considering different time intervals, the method uses the ordinary least squares (OLS) regression analysis method to determine the optimal time interval parameter of the lithium battery. The training set divided by two datasets is used to establish a multiple linear regression model, and the validation set divided by two datasets is used to verify the method. The experimental results show that the proposed method and novel health feature can greatly reduce the calculation volume, and can achieve fast estimation of lithium battery SOH while ensuring prediction accuracy.

**Keywords:** lithium battery; state of health (SOH) estimation; novel health feature; data-driven approach; multiple linear regression (MLR); charging voltage data fragment

(编辑 吴昊)