

基于电压极差特征的储能电池组早期健康状态检测

朱沐雨, 马宏忠*, 宣文婧

(河海大学 能源与电气学院, 江苏南京 211100)

Early Health Status Detection of Energy Storage Battery Pack Based on Voltage Range Characteristics

ZHU Muyu, MA Hongzhong*, XUAN Wenjing

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: In order to evaluate the state of health (SOH) of energy storage battery packs more efficiently, an early health status detection method based on voltage range characteristics is proposed. Firstly, the cyclic aging experiment is carried out based on the large-capacity lithium iron phosphate battery pack, and the voltage range signal of each cycle is measured, and the voltage characteristics of key time points are extracted from it. Secondly, health factors highly related to battery aging are screened based on Pearson correlation coefficient and grey correlation degree analysis (GRA). Finally, the Sparrow search algorithm (SSA) is used to optimize Bi-directional long short-term memory (BiLSTM) hyperparameters, and SSA-BiLSTM health state estimation model is built, and realize SOH evaluation of energy storage battery pack. The effectiveness of the health factor and the superiority of the estimation model are verified by the conventional machine learning algorithm. The results show that the extracted voltage range characteristics of charging and discharging for 30 min can effectively reflect the decline trend of battery pack capacity, and the estimated error of SOH is less than $\pm 0.8\%$ under various models. The root mean square error (RMSE) of the SSA-BiLSTM model proposed in this paper is as low as 0.07%. Therefore, this method can effectively monitor the SOH of large-capacity energy storage battery packs online.

Key words: lithium iron phosphate energy storage battery pack; health status assessment; voltage range; sparrow

基金项目: 国家自然科学基金项目(51577050); 国网江苏省电力有限公司重点科技项目(J2022158)

National Natural Science Foundation Project (51577050); Technology Project of State Grid Jiangsu Power Co., LTD (J2022158)

search algorithm; bidirectional long short-term memory network; online monitoring

摘要: 为了更加高效地评估储能电池组的健康状态(SOH),提出一种基于电压极差特征的早期健康状态检测方法。首先基于大容量磷酸铁锂储能电池组开展循环老化试验,测量每次循环的电压极差信号,并从中提取关键时间点的电压特征;其次,基于皮尔逊(Pearson)相关系数及灰色关联度分析法(GRA)筛选与电池组老化高度相关的健康因子。最后,通过麻雀搜索算法(SSA)优化双向长短时记忆网络(BiLSTM)的超参数,搭建 SSA-BiLSTM 健康状态估计模型,实现储能电池组 SOH 评估;并结合常规机器学习算法验证了健康因子的有效性和估计模型的优越性。结果表明,所提取充放电静置 30 min 的电压极差特征能够有效反映电池组容量衰退趋势,多种模型验证下 SOH 估计误差均低于 $\pm 0.8\%$ 。其中,本文所提出的 SSA-BiLSTM 模型均方根误差(RMSE)低至 0.07%。因此该方法能够有效地对大容量储能电池组的 SOH 实现在线监测。

关键词: 磷酸铁锂储能电池组; 健康状态评估; 电压极差; 麻雀搜索算法; 双向长短时记忆网络; 在线监测

0 引言

随着我国新型电力系统建设的不断推进,大规模新能源并网对电网的稳定运行提出了巨大挑战,电力系统对储能的需求日益增多。锂离子电池储能技术具有效率高、应用灵活以及响应速度快等优点,逐渐在电力储能市场占有越来越重要的地位^[1-4]。然而,储能电站实际运行工况复杂,长期工作的储能锂离子电池组会出现不一致性扩大、性能衰退加剧和各测量指标估算精度下降等

问题,严重制约了储能电站的安全运行。因此,准确可靠地估计和检测电池的健康状态(SOH),能够有效评估电池的使用寿命和老化程度,对于确保储能系统安全稳定运行至关重要^[4-6]。

单体电池 SOH 的估算包括健康因子的提取和预测模型的建立两个方面。目前,随着深度学习算法的发展,基于数据驱动的 SOH 估计模型克服了复杂的等效建模和参数辨识问题,有较好的应用前景^[7]。主流方法包括支持向量回归、高斯过程回归以及长短时记忆神经网络^[8-10]等。

同时,国内外学者对健康因子的提取也进行了大量研究。文献[11]基于电池充电电压曲线和容量增量曲线提取多个特征,并通过随机森林算法中的基尼系数计算出各个特征的重要程度;文献[12]分析了恒定充电过程中的温差曲线,在规定电压范围内使用支持向量回归建立与 SOH 的关系;文献[13]对电压、电流、温度采样序列进行卷积处理,结合长短时记忆(Long Short-Term Memory, LSTM)网络和注意力机制实现 SOH 估算。

对于电池组健康状态估计,现有文献大都由单体至整体进行分析。文献[14]提出了一种基于单体到模组迁移的磷酸铁锂储能系统 SOH 评估方法,研究结果表明经过小规模样本数据优化后的电池单体模型能够实现对电池组 SOH 的评估;文献[15]通过对电池组内特征单体进行建模,在同时考虑单体容量退化和内阻增大的前提下,预测电池组的实际可充入电量。文献[16]基于敏感电化学参数等健康因子,利用非线性系数温度递减步长模拟退火-反向传播神经网络(Nonlinear Coefficient Temperature Decreasing Step Size Simulated Annealing-Back Propagation, NSA-BP)神经网络对储能电池组各单体的 SOH 进行了估算,并选择最小值作为整组的 SOH。

然而,实时对电池组内各单体进行分析的工作量较大,不适用于实际储能电站中对众多大容量电池组的运维^[17]。且部分文献所提出的健康特征难以直接获取,或是只适用于单体电池,无法反映整个电池组的运行特征。

对此,本文采用 220 Ah 大容量磷酸铁锂储能电池组进行循环老化试验,并提出一种基于电压极差特征的电池组 SOH 检测方法。电压极差储能电站易于测量,且该方法不需要考虑电池组内各单体

的容量变化,减少了工作量。进一步地,通过相关性分析法从测量信号中提取高度相关的特征向量集。接着,利用 SSA 优化的 BiLSTM 模型实现对电池组的健康状态评估;最后通过对所建模型的估计误差进行评估,验证该检测方法的可行性。

1 电池组相关参数

本文所研究的储能电池组均为串联电池组。由于单体电池间容量各不相同,一致性较差的单体总是率先达到充放电截止电压^[18],此时如果电池组继续工作会导致该单体发生过充过放,进一步影响整体性能。因此电池组健康状态可从容量和内阻角度定义,如下^[19]:

$$\text{SOH} = \frac{C_{\text{pcap}}}{C_{\text{icap}}} \times 100\% \quad (1)$$

$$\text{SOH} = \frac{R_{\text{trse}} - R_{\text{prse}}}{R_{\text{trse}} - R_{\text{irse}}} \times 100\% \quad (2)$$

式中: C_{pcap} 为电池组中当前锂电池组最大放电容量; C_{icap} 为电池组额定容量; $R_{\text{trse}}, R_{\text{prse}}, R_{\text{irse}}$ 分别为寿命中止、当前状态、初始状态的电池欧姆内阻。

由于容量法参数易于获取,本文主要从容量的角度考虑 SOH。

荷电状态(State of Charge, SOC)表征当前电池组剩余电量,是保证电池组安全可靠运行的重要参数之一,计算方法如式(2)所示:

$$\text{SOC} = 1 - Q/Q_z \times 100\% \quad (3)$$

式中: Q 为放出电量; Q_z 为电池组当前总电量。

电池组电压极差反映了组内电池运行状态的差异,是评估电池组一致性的主要指标,其定义如下:

$$\Delta U = U_{\text{max}} - U_{\text{min}} \quad (4)$$

式中: U_{max} 为电池组内单体电压最大值; U_{min} 为电池组内单体电压最小值。

由于电压易于直接测量和获取,且在电池组早期容量衰减过程中差异性明显,因此本文选取电压极差而非电池组内阻、温度极差作为表征 SOH 变化的指标。

2 算法介绍

2.1 相关性分析

皮尔逊(Pearson)相关系数是用于度量两个随机变量之间线性相关程度的指标,相关系数计算表达式如下^[7]:

$$\rho_{XY} = \frac{E(X, Y) - E(X)E(Y)}{\sqrt{E(X^2) - E(X)^2} \cdot \sqrt{E(Y^2) - E(Y)^2}} \quad (5)$$

式中: E 为均值计算; X 和 Y 为电池组容量衰减特征序列。变量之间相关程度越高, 皮尔逊相关系数越接近 ± 1 。

灰色关联度分析是一种基于灰色系统理论的多因素统计方法, 通过分析各因素变化趋势的相似程度来判断因素之间的关联程度。其计算方法如下^[20]:

$$\begin{aligned} f_i(k) = \\ \min_{i} \min_k |y(k) - x_i(k)| + \rho \max_{i} \max_k |y(k) - x_i(k)| \\ |y(k) - x_i(k)| + \rho \max_{i} \max_k |y(k) - x_i(k)| \end{aligned} \quad (6)$$

式中: $y(k)$ 为电池组健康状态; k 为时步数; ρ 为分辨系数, 一般取 0.5; $x_i(k)$ 为第 i 个特征序列中第 k 个特征值, i 为特征序列个数。

进一步计算不同特征的相关性 r :

$$r = \frac{1}{n} \sum_{k=1}^n f_i(k) \quad (7)$$

2.2 双向长短时记忆网络

BiLSTM 是 LSTM 的变体结构, LSTM 网络此处不再赘述, BiLSTM 结构图如图 1 所示。该网络由前向 LSTM 与后向 LSTM 层构成, 可以同时深度挖掘数据的历史和未来信息, 提高预测精度。BiLSTM 最终输出结果如式(8)所示:

$$h_t = \vec{h}_t \odot \tilde{h}_t \quad (8)$$

式中: \vec{h}_t 为 BiLSTM 的正向输出; \tilde{h}_t 为 BiLSTM 的反向输出。

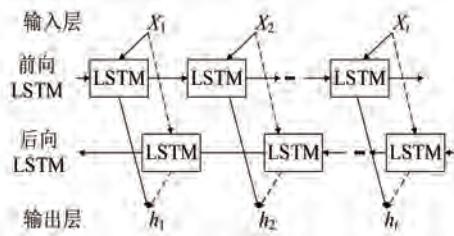


图 1 BiLSTM 网络结构

Fig. 1 BiLSTM network structure

2.3 麻雀搜索算法

麻雀搜索算法(SSA)是 2020 年提出的一种优化算法, 其灵感来自麻雀的捕食和反捕食行为。该算法收敛速度快、鲁棒性强, 能够较好地解决多参数优化问题。SSA 主要流程如下^[21]:

设共有 N 只麻雀, 其中种群位置最优的记为 P 只, 作为发现者; 剩余($N-P$)只作为跟随者。 D 维解空间中, 每只麻雀的位置设为 $x = \{x_1, x_2, \dots, x_D\}$, $f = f\{x_1, x_2, \dots, x_D\}$ 作为其适应度值。在每次迭代过程中, 发现者位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot iter_{\max}}\right), & R_2 < S_T \\ X_{i,j}^t + Q, & R_2 \geq S_T \end{cases} \quad (9)$$

式中: $X_{i,j}$ 为第 i 只麻雀在第 j 维的信息; t 为当前迭代次数; $\alpha \in (0, 1]$ 为随机数; $iter_{\max}$ 为最大迭代次数; $R_2 \in [0, 1]$ 为安全值; $S_T \in [0.5, 1]$ 为预警值; Q 为正态分布随机数。

跟随者位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), & i > N/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+, & \text{其他} \end{cases} \quad (10)$$

式中: X_{worst}^t 为全局最差位置; X_p^{t+1} 为最佳位置; A^+ 为元素随机 ± 1 的矩阵。

当麻雀意识到危险时, 会放弃当前食物, 进行预警行为:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t|, & f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right), & f_i = f_g \end{cases} \quad (11)$$

式中: X_{best}^t 为全局最优位置; β 为标准正态分布的控制参数; $K \in [-1, 1]$; ε 为较小数, 防止分母为零; f_i 为当前麻雀的个体适应度值; f_w 为最差位置适应度值; f_g 为最佳位置适应度值。

2.4 误差评价指标

为了更好地评估所提模型的精度, 本文引入均方根误差(RMSE)、平均绝对误差(Mean Absolute Error, MAE) 来度量误差大小, 表达式如下^[7]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_1 - y_i)^2} \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_1 - y_i| \quad (13)$$

式中: y_1 为 SOH 真实值序列; y_i 为第 i 次循环下的 SOH 估算结果; n 为电池组的充放电循环总次数。

结合上述算法分析, 可初步构建电池组 SOH 检测方法流程图, 如图 2 所示。

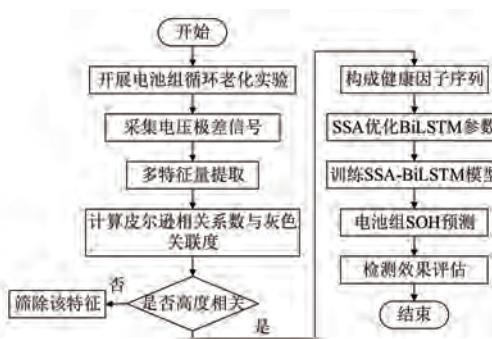


图 2 检测方法流程图

Fig. 2 Flow chart of the detection method

3 试验设计与分析

3.1 试验平台搭建

本文选取比亚迪梯次利用电池组作为试验对象,规格型号为 MCRSA08-LC,其由 8 块 220 Ah 的方型磷酸铁锂电池单体串联而成,如图 3 所示,其具体参数如表 1 所示。



图 3 大容量磷酸铁锂电池组

Fig. 3 Large capacity lithium iron phosphate battery pack

表 1 电池组的参数

Tab. 1 Parameters of the battery pack

参数名称	参数值
标称电压/V	25.6
标称容量/Ah	220 ($\pm 10\%$)
电池组尺寸/(mm \times mm \times mm)	555 \times 430 \times 154
单体充电截止电压/V	3.8
单体放电截止电压/V	2.7
工作温度/°C	-20~55

完整的试验平台如图 4 所示,采用宁波拜特 BT60V300AC2 型号的电池测试系统,可测电压范围为 0~60 V,最大充放电电流 300 A。温控箱为 HCEPET 生产的 HCJB1000L-20 高低温交变湿热试验箱,可测温度范围为 -20~100 °C,电池组置于其中。上位机用于设置充放电指令和数据监测。



图 4 电池测试平台

Fig. 4 Battery testing experimental platform

试验方案如下:设置环境温度为恒定 25 °C,将电池组电量放空并充分静置。如图 5 所示,采用恒流 0.5 C(约 110 A)充至截止条件(某一单体 U-Cell ≥ 3.65 V),静置 30 min;采用恒流 0.5 C 放至放电截止条件(某一单体 U-Cell ≤ 2.7 V),静置 30 min,记录此时电池组最大容量,以此作为一次充放电循环。利用该充放电规范进行长期循环老化试验,并通过上位机监测软件实时获取电池电压、电流以及温度等参数。

试验采用恒定电流是因为在满充满放恒流工况下,电池组每个老化循环下的最大可放电容量可以通过采集的电流和时间数据进行精准计算;如果按照复杂储能工况,则只能通过核容测试获取最大放电容量,试验数据点难以短时间内获取。此外,实际储能工况平均倍率约为 0.5 C,故采用 0.5 C 恒流。

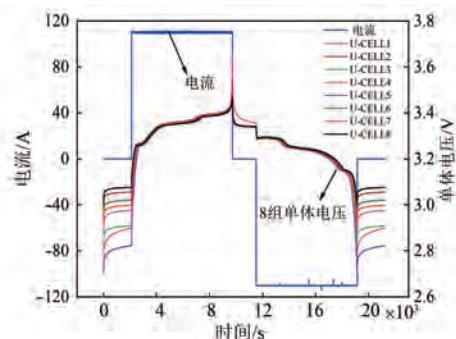


图 5 充放电过程中的电流电压曲线

Fig. 5 Current voltage curve during charging and discharging process

3.2 电压极差特征提取

试验测得初始电池组容量为 240 Ah,经历 720 次循环后,容量衰减至 218 Ah。电池组容量随充放电循环的退化曲线如图 6 所示。

图 7 展示了不同循环次数下组内各单体电压极差的变化情况。考察某一循环周期的电压极差

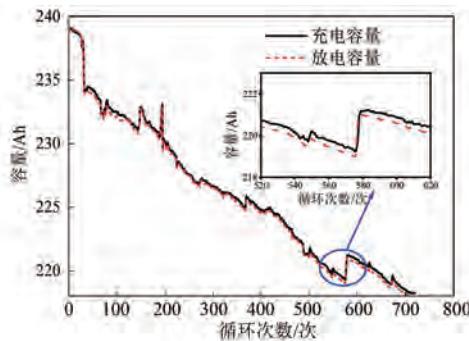


图 6 电池组容量退化曲线

Fig. 6 Battery pack capacity degradation curve

曲线,由于磷酸铁锂电池的特性,在 SOC 小于 10% 时,电压随充放电变化明显;又因为组内部各单体容量存在差异,电压极差被进一步放大,这种情况在放电至 SOC=0% (达到某一单体电压截止条件) 时尤为明显,极差可达 340 mV (图 7 中 E 处)。因此,会呈现出放电末期电压极差迅速上升、充电初期电压极差骤降的现象。当电池 SOC 接近 100% 时,也会出现极差上升的情况,可达 200~225 mV (图 7 中 B 处)。静置阶段电压极差随时间变化(图 7 中 A、C 处),这是由于静置过程中电池的欧姆极化降为零,内部的电化学极化和浓差极化不会随着电流的切断而立即消失,从而引起电压弛豫,但随时间变化逐渐趋于稳态,进而差值变小。

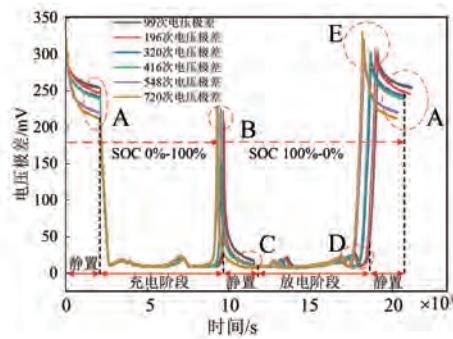


图 7 不同循环次数下单一电压极差曲线

Fig. 7 Individual voltage range curve under different cycle times during charging and discharging process

考察不同循环次数的电压极差曲线,可以看出,放电截止后的静置阶段(图 7 中 A 处),随着循环次数的上升,电压极差呈现出规律性下降:第 99 次循环时极差约为 257 mV,而第 720 次循环后极差已衰减至 213 mV,与电池组容量退化的趋势相同。这是由于一致性较差的单体电池容量完全

放出,导致充电截止电压较高,放电截止电压较低;随着电池老化加剧,一致性较差的单体极化电压变化幅度更大,进一步导致电压极差减小。此外,随着循环次数增加,完成整个电压极差变化周期所用的时间明显缩短,在图中表现为 B、D、E 处,较高循环次数的极差曲线总是率先达到峰值点和转折点。

根据上述分析,初步提取电压极差曲线中的特征参数如下:充电/放电后静置 30 min 的电压极差 $U_{\text{schar}}/U_{\text{sdis}}$;充电/放电截止时的电压极差 $U_{\text{echar}}/U_{\text{edis}}$;电压极差变化周期 T_{range} 。

3.3 健康因子筛选

对于上述提取的 $U_{\text{schar}}/U_{\text{sdis}}$ 、 $U_{\text{echar}}/U_{\text{edis}}$ 、 T_{range} 五组特征参数,采用皮尔逊相关系数和灰色关联度分析法量化衡量与电池簇健康状态的相关性。皮尔逊相关系数的绝对值、灰色关联度越接近 1, 表明所提取的特征序列与电池组健康状态相关性越强, 相关性分析结果如表 2 所示。本文保留皮尔逊相关系数绝对值大于 0.8、灰色关联度大于 0.7 的特征参数(即 $U_{\text{schar}}/U_{\text{sdis}}$), 作为后续健康状态监测模型的输入。

表 2 特征相关性分析结果

Tab. 2 Feature correlation analysis results

特征参数	皮尔逊相关系数	灰色关联度
$U_{\text{schar}}/\text{mV}$	0.979 5	0.742 8
$U_{\text{sdis}}/\text{mV}$	0.983 5	0.959 4
$U_{\text{echar}}/\text{mV}$	-0.745 1	0.570 6
$U_{\text{edis}}/\text{mV}$	-0.802 6	0.677 5
$T_{\text{range}}/\text{s}$	0.941 5	0.683 9

4 模型效果验证

本文将 720 组电池组循环老化数据约以 5:2 进行划分,其中训练集 500 组,测试集 220 组。利用麻雀搜索优化算法对 BiLSTM 网络的学习率、隐含层神经元个数以及训练次数进行寻优,设置麻雀搜索算法种群数目为 15,最大迭代次数为 20 次,预警值 S_T 为 0.7,其适应度进化曲线如图 8 所示。图 8 中的拐点处表明 SSA 算法成功跳出局部极值继续寻优,且在第 7 次迭代时已收敛到全局最优解。此时,隐含层神经元为 119、初始学习率为 0.019 1、最大训练次数为 148,可认为 BiLSTM 网络性能达到最优。

图 9 展示了所建立的 SSA-BiLSTM 模型对储

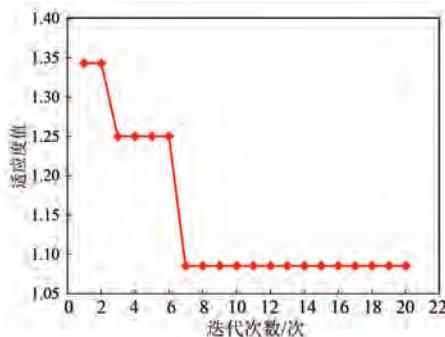


图 8 SSA 适应度进化曲线

Fig. 8 SSA fitness evolution curve

能电池组健康状态的预测结果,并与传统的 SOH 估计机器学习方法进行了对比,包括高斯过程回归(GPR)、支持向量机(SVM)、长短时记忆网络(LSTM)。其中,GPR 选用径向基核函数,核函数超参数 σ_1 设为 5.7, 标准差 σ_f 设为 4.5; SVM 惩罚因子 c 设为 4.0, 选用径向基核函数,核函数参数 g 设为 0.1; LSTM 隐含层神经元设为 100, 训练次数 350 次, 初始学习率 0.02。各训练集、测试集划分比例与 SSA-BiLSTM 相同。

图 10 展示了 SOH 估计的绝对误差。对于所提取的健康因子,SOH 估计误差均在 $\pm 0.8\%$ 以内,说明电压极差特征应用于电池组健康状态在线监测具有可行性。

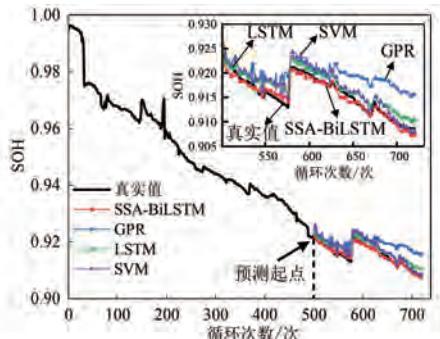


图 9 模型预测结果

Fig. 9 Model prediction results

相比 SSA-BiLSTM 模型,GPR 参数优化复杂,且参数选择对精度影响高^[7]; SVM 对异常值较为敏感,鲁棒性较差^[22]; LSTM 仅依靠正向序列信息进行预测,有一定局限性^[23]。各模型的 RMSE、MAE 评估结果如表 3 所示。可以看出,SSA-BiLSTM 模型的 $RMSE = 7.108 \times 10^{-4}$ 、 $MAE = 6.08 \times 10^{-4}$,较其他模型更具优越性,预测结果更接近真实值。因此在实际应用中,通过易直接测量的电

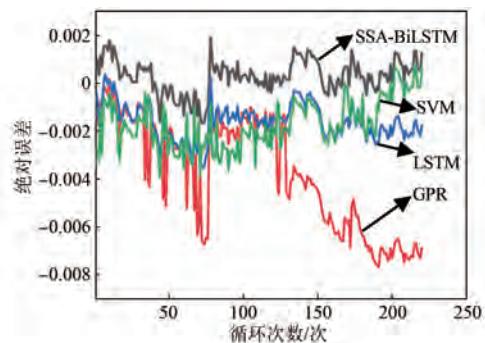


图 10 SOH 估计绝对误差

Fig. 10 Absolute error in SOH estimation

压极差特征,结合本文所建模型,能够实时反映当前电池组的健康状态,为储能电站的早期故障预警提供有力保障。后续研究将在典型调峰/调频工况下进行 SOH 评估,进一步验证模型的泛化能力并作出改进。

表 3 各模型评估结果

Tab. 3 Evaluation results of each model

模型	RMSE	MAE
SSA-BiLSTM	7.108×10^{-4}	6.08×10^{-4}
GPR	4.726×10^{-3}	3.77×10^{-3}
LSTM	1.749×10^{-3}	1.60×10^{-3}
SVM	1.886×10^{-3}	1.76×10^{-3}

5 结语

针对大容量电池组健康状态估算复杂的问题,本文提出了一种基于单体电压极差的储能电池组早期健康状态检测方法。通过开展储能电池组循环老化试验,提取电压极差特征应用于 SOH 估计。结果表明,所提取的电压极差特征不仅易于获取,且在常规 SOH 估计模型下,预测绝对误差均低于 $\pm 0.8\%$ 。因此,电压极差特征能够作为健康因子评估电池组的健康状态,有效避免了对组内单体电池逐一估计,减少了电池组 SOH 检测的复杂度,有利于储能电站的安全运行与维护。同时,进一步建立 SSA-BiLSTM 估计模型,相较于常规模型检测精度更高,稳定性更好,能有效地应用于大容量储能电池组 SOH 在线监测。

参 考 文 献

- [1] 马宏忠, 吴元熙, 劳文洁, 等. 基于 MRSVD 和时频灰度图的储能电池过充特征识别 [J]. 电源技术, 2020, 44(9): 1351-1355.

- MA H Z, WU Y X, LUO W J, et al. Identification of overcharge characteristics of energy storage batteries based on MRSVD and time-frequency grayscale image [J]. Chinese Journal of Power Sources, 2020, 44 (9): 1351-1355.
- [2] 黄庆祥, 郭玲, 刘修童, 等. 风-光储能系统锂离子电池 SOC 校准优化方法[J]. 电机与控制应用, 2023, 50(3): 95-99+107.
- HUANG Q X, GUO L, LIU X T, et al. Optimization method of SOC calibration for lithium-ion battery in wind-optical energy storage system [J]. Electric Machines & Control Application, 2023, 50(3): 95-99+107.
- [3] WANG Q S, MAO B B, STOLIAROV S I, et al. A review of lithium ion battery failure mechanisms and fire prevention strategies [J]. Progress in Energy and Combustion Science, 2019, 73: 95-131.
- [4] 金阳, 薛志业, 姜欣, 等. 储能锂离子电站安全防护研究进展[J]. 郑州大学学报(理学版), 2023, 55(3): 1-13.
- JIN Y, XUE Z Y, JIANG X, et al. Research progress of safety protection of lithium-ion energy storage power station [J]. Journal of Zhengzhou University (Natural Science Edition), 2023, 55(3): 1-13.
- [5] BULLICH M E, GARCIA F, GLENNY C I, et al. A review of energy storage technologies for large scale photovoltaic power plants [J]. Applied Energy, 2020, 274(15): 115213-115224.
- [6] 顾菊平, 蒋凌, 张新松, 等. 基于特征提取的锂离子电池健康状态评估及影响因素分析[J]. 电工技术学报, 2023, 38(19): 5330-5342.
- GU J P, JIANG L, ZHANG X S, et al. Estimation and influencing factor analysis of lithium-ion batteries state of health based on features extraction [J]. Transactions of China Electrotechnical Society, 2023, 38(19): 5330-5342.
- [7] 李放, 闵永军, 王琛, 等. 基于充电过程的锂电池 SOH 估计和 RUL 预测 [J]. 储能科学与技术, 2022, 11(10): 3316-3327.
- LI F, MIN Y J, WANG C, 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): 3316-3327.
- [8] 徐佳宁, 倪裕隆, 朱春波. 基于改进支持向量回归的锂电池剩余寿命预测 [J]. 电工技术学报, 2021, 36(17): 3693-3704.
- XU J N, NI Y L, ZHU C B. Remaining useful life prediction for lithium-ion batteries based on improved support vector regression [J]. Transactions of China Electrotechnical Society, 2021, 36(17): 3693-3704.
- [9] LIU W, XU Y, FENG X. A hierarchical and flexible data-driven method for online state-of-health estimation of Li-ion battery [J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 14739-14748.
- [10] 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 C J, WANG Y N, LI P F, 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.
- [11] 武骥, 方雷超, 刘兴涛, 等. 基于特征优化和随机森林算法的锂离子电池 SOH 估计 [J]. 机械工程学报, 2022, 58: 1-9.
- WU J, FANG L C, LIU X T, et al. State of health estimation of lithium-ion battery based on feature optimization and random forest algorithm [J]. Journal of Mechanical Engineering, 2022, 58: 1-9.
- [12] TIAN J P, XIONG R, SHEN W X. State of health estimation based on differential temperature for lithium-ion batteries [J]. IEEE Transactions on Power Electronics, 2020, 35(10): 10363-10373.
- [13] 楚瀛, 陈一凡, 米阳. 一种基于注意力机制的 CNN-LSTM 锂电池健康状态估算 [J]. 电源技术, 2022, 46(6): 634-637+651.
- CHU Y, CHEN Y F, MI Y. Lithium battery health state estimation based on attention mechanism-CNN-LSTM [J]. Chinese Journal of Power Sources, 2022, 46(6): 634-637+651.
- [14] 杨智鹏, 宋政湘, 孟锦豪, 等. 基于单体到模组迁移的磷酸铁锂储能系统 SOH 评估方法 [J]. 高电压技术, 2023, 49(10): 4142-4149.
- YANG Z P, SONG Z X, MENG J H, et al. SOH evaluation method for LFP energy storage system based on cell-to-module transfer [J]. High Voltage Engineering, 2023, 49(10): 4142-4149.
- [15] 张瑛, 康永哲, 段彬, 等. 基于数据-模型双驱动的电池组容量在线估计 [J/OL]. 机械工程学报,

- 2023-11-04. <https://link.cnki.net/urlid/11.21.87.TH.20230428.1431.020>.
- ZHANG Y, KANG Y Z, DUAN B, et al. Online estimation of battery pack capacity based on dual driven method of data and model [J/OL]. Journal of Mechanical Engineering, 2023-11-04. <https://link.cnki.net/urlid/11.2187.TH.20230428.1431.020>.
- [16] 熊然. 基于电化学机理和数据驱动的储能锂电池簇SOH估算方法研究[D]. 绵阳:西南科技大学, 2023.
- XIONG R. Research on SOH estimation method of lithium battery pack based on electrochemical mechanism and data-driven [D]. Mianyang: Southwest University of Science and Technology, 2023.
- [17] 高欣, 王若谷, 高文菁, 等. 基于运行数据的储能电站电池组一致性评估方法[J]. 储能科学与技术, 2023, 12(9): 2937-2945.
- GAO X, WANG R G, GAO W J, et al. Consistency evaluation method of battery pack in energy storage power station based on running data [J]. Energy Storage Science and Technology, 2023, 12(9): 2937-2945.
- [18] 李佳娜, 刘丹丹, 朱峰, 等. 基于电力调频的串联锂离子电池组均衡技术分析[J]. 储能科学与技术, 2019, 8(3): 468-476.
- LI J N, LIU D D, ZHU F, et al. Analysis of equalization technology of series lithium-ion battery pack based on power frequency modulation [J]. Energy Storage Science and Technology, 2019, 8(3): 468-476.
- [19] 张朝龙, 赵筛筛, 何怡刚. 基于信息熵与PSO-LSTM的锂电池组健康状态估计方法[J]. 机械工程学报, 2022, 58(10): 180-190.
- ZHANG C L, ZHAO S S, HE Y G. State-of-health estimate for lithium-ion battery using information entropy and PSO-LSTM [J]. Journal of Mechanical Engineering, 2022, 58(10): 180-190.
- [20] 周才杰, 汪玉洁, 李凯铨, 等. 基于灰色关联度分析-长短期记忆神经网络的锂离子电池健康状态估计[J]. 电工技术学报, 2022, 37(23): 6065-6073.
- ZHOU C J, WANG Y J, LI K Q, et al. State of health estimation for lithium-ion battery based on gray correlation analysis and long short-term memory neural network [J]. Transactions of China Electrotechnical Society, 2022, 37(23): 6065-6073.
- [21] 臧旭, 张甜瑾, 邵心悦, 等. 基于时变滤波经验模态分解和SSA-LSSVM的变压器内部机械故障诊断方法[J]. 电机与控制应用, 2023, 50(9): 49-56.
- ZANG X, ZHANG T J, SHAO X Y, et al. A transformer internal mechanical fault diagnosis method based on TVFEMD and SSA-LSSVM [J]. Electric Machines & Control Application, 2023, 50(9): 49-56.
- [22] 崔兆亿, 耿秀丽. 基于随机森林和量子粒子群优化的SVM算法[J]. 计算机集成制造系统, 2023, 29(9): 2929-2936.
- CUI Z Y, GENG X L. Support vector machine algorithm based on random forest and quantum particle swarm optimization [J]. Computer Integrated Manufacturing Systems, 2023, 29(9): 2929-2936.
- [23] 王义, 刘欣, 高德欣. 基于BiLSTM神经网络的锂电池SOH估计与RUL预测[J]. 电子测量技术, 2021, 44(20): 1-5.
- WANG Y, LIU X, GAO D X. The SOH estimation and RUL prediction of lithium battery based on BiLSTM [J]. Electronic Measurement Technology, 2021, 44(20): 1-5.

收稿日期:2023-11-05

收到修改稿日期:2023-12-11

作者简介:

朱沐雨(2000-),男,硕士研究生,研究方向为电池储能安全技术,962307019@qq.com;

*通信作者:马宏忠(1962-),男,博士,教授,研究方向为电力设备故障诊断和电力设备状态监测,hhumhz@163.com。

Early Health Status Detection of Energy Storage Battery Pack Based on Voltage Range Characteristics

ZHU Muyu, MA Hongzhong*, XUAN Wenjing

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Key words: lithium iron phosphate energy storage battery pack; health status assessment; voltage range; sparrow search algorithm; bidirectional long short-term memory network; online monitoring

The actual operation condition of the energy storage power station is complex, and the problems of the long-term operation of the energy storage lithium-ion battery pack will appear the expansion of inconsistency, the deterioration of performance, and the decline of the estimation accuracy of each measurement index, which seriously restricts the safe operation of the energy storage power station. Therefore, accurate and reliable estimation and detection of state of health (SOH) battery can effectively evaluate the service life and aging degree of the battery, which is crucial to ensure the safe and stable operation of the energy storage system.

This paper presents an early health detection method based on voltage range characteristics. Firstly, the cyclic aging experiment is carried out based on the large-capacity lithium iron phosphate battery pack, and the voltage range signal of each cycle is measured, and the voltage characteristics of key time points are extracted from it.

Secondly, health factors highly related to battery

aging are screened based on Pearson correlation coefficient and grey correlation degree analysis (GRA).

Finally, the Sparrow search algorithm (SSA) is used to optimize the hyperparameters of BiLSTM, the SSA-BiLSTM health state estimation model is built, and realize the SOH evaluation of the energy storage battery pack. The effectiveness of the health factor and the superiority of the estimation model are verified by the conventional machine learning algorithm. The overall process is shown in Fig.1.

The results show that the extracted voltage range characteristics of charging and discharging for 30 min can effectively reflect the decline trend of battery pack capacity, and the estimated error of SOH is lower than $\pm 0.8\%$ under various models. The root mean square error (RMSE) of the SSA-BiLSTM model proposed in this paper is as low as 0.07%. Therefore, this method can effectively monitor the SOH of large-capacity energy storage battery packs online.

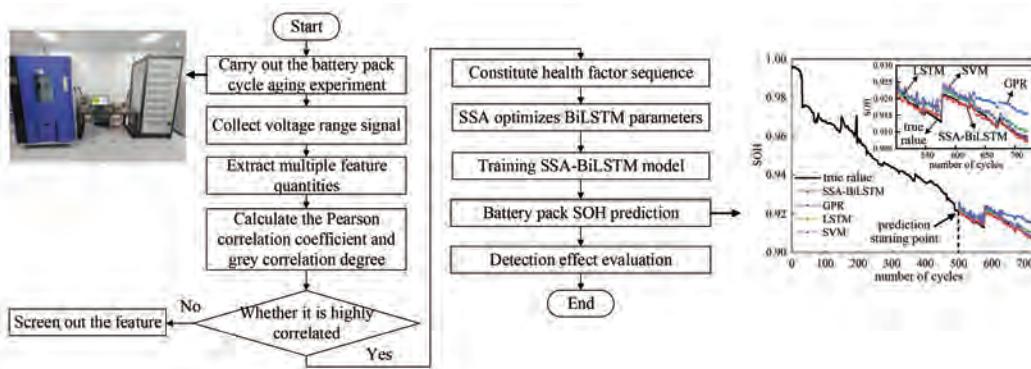


Fig. 1 Flow chart of the detection method