

引用格式: 杨 奋, 郭宜果, 黄小庆, 等. 基于二值化神经网络的大规模储能电站电池容量衰退预测[J]. 电力科学与技术学报, 2025, 40(2): 227-234.

Citation: YANG Hang, GUO Yiguo, HUANG Xiaqing, et al. Battery capacity degradation prediction of large-scale energy storage power station based on binary neural network[J]. Journal of Electric Power Science and Technology, 2025, 40(2): 227-234.

基于二值化神经网络的大规模储能电站 电池容量衰退预测

杨 奋¹, 郭宜果¹, 黄小庆², 文普同², 谢 丹¹, 薄其滨¹, 付一木¹, 李静璇¹

(1. 国网山东省电力公司经济技术研究院, 山东 济南 250021; 2. 湖南大学电气与信息工程学院, 湖南 长沙 410082)

摘 要: 大规模储能电站的电池单体数量庞大。传统卷积神经网络在电池容量衰退预测中具备较高的预测精度, 但其对计算资源需求较高, 限制了其在储能电站电池管理系统中的应用。为此, 提出一种基于二值化神经网络(binary neural network, BNN)的电池容量衰退预测方法。首先, 设计一个将网络权重和激活函数二值化的轻量化模型, 并以电池的放电容量-电压曲线作为输入, 输出关键参数的累积分布函数值。其次, 通过二分法求解该参数, 并将其代入双曲线方程进行容量衰退预测。最后, 基于锂电池公开数据集仿真表明: 在预测精度与传统神经网络模型相当的情况下, 所提模型的参数量减少 48.9%, 预测速度提升 22.37%, 可降低模型复杂度和设备算力成本, 为大规模储能电站电池管理提供一个更高效、更轻量的预测方法。

关 键 词: 储能电站; 电池容量; 衰退预测; 二值化神经网络; 卷积神经网络

DOI: 10.19781/j.issn.1673-9140.2025.02.024 中图分类号: TM912 文章编号: 1673-9140(2025)02-0227-10

Battery capacity degradation prediction of large-scale energy storage power station based on binary neural network

YANG Hang¹, GUO Yiguo¹, HUANG Xiaqing², WEN Putong², XIE Dan¹,
BO Qibin¹, FU Yimu¹, LI Jingxuan¹

(1. Economic & Technology Research Institute, State Grid Shandong Electric Power Company, Jinan 250021, China;

2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: The number of battery cells in a large-scale energy storage power station is enormous. The conventional convolutional neural networks achieve high prediction accuracy for battery capacity degradation. However, they have high demand for computational resources, which limits their application in practical battery management systems of energy storage power stations. To solve this problem, this paper proposes a battery capacity degradation prediction method based on a binary neural network. First, a lightweight model is designed by binarizing the network weights and activation functions, using the discharge capacity-voltage curve of the battery as input to output the cumulative distribution function values of key parameters. Subsequently, these parameters are solved using the bisection method and substituted into a hyperbola equation to predict the capacity degradation curve. Finally, experiments are conducted on a public lithium-ion battery dataset. The results show that under the same prediction accuracy as traditional neural network models, the proposed model reduces the number of parameters by 48.9% and improves prediction speed by 22.37%. This study reduces model computational complexity and hardware computational cost and also provides a more efficient and lightweight prediction method for battery management in large-scale energy storage power stations.

Keywords: energy storage power station; battery capacity; degradation prediction; binary neural network; convolutional neural network

收稿日期: 2024-09-05; 修回日期: 2024-11-18

基金项目: 山东智源电力设计咨询有限公司项目(SGSDJY00ZYJS2310255)

通信作者: 黄小庆(1981—), 女, 副教授, 博士, 主要从事电力系统分析、电动汽车入网研究、电力大数据方面的研究; E-mail: huangxiaqing@hnu.edu.cn

为平衡能源供给波动,储能电站得到广泛应用^[1-2]。目前,电化学储能,尤其是锂电池储能,因其较高的能量密度和充、放电效率,成为主流发展方向^[3-4]。然而,锂电池的容量会随着充、放电次数的增加而衰退,导致储能系统整体性能下降,并带来安全隐患^[5-6]。准确预测电池容量衰退状态^[7-8],进而优化储能电站运行策略,是当前亟待解决的关键问题。

当前,电池容量衰退预测方法主要分为3类:直接测量法^[9]、基于物理模型的方法^[10]和基于数据驱动的方法^[11]。直接测量法依赖电池容量、内阻等参数的精确测量,虽预测精度高,但依赖昂贵设备,难以实现在线监测^[12-13]。基于物理模型的方法通过构建电池内部电化学模型描述衰退过程,但模型参数易受环境干扰,且内部反应机理复杂,导致预测稳定性不足^[14-15]。

基于数据驱动的方法因无须依赖物理模型、显著简化预测流程,成为近年研究热点^[16-17]。例如高斯过程回归、支持向量机和神经网络^[18-19]等,已展现出良好的容量预测性能。文献[20]建立以健康因子为输入,电池容量退化量为输出的高精度灰色神经网络模型,但需要引入欧姆内阻和极化内阻的增加量,以及极化电容减少量等健康因子,检测成本较高。文献[21]通过构造观测器,将高斯过程回归与指数经验模型有效组合,实现对锂电池的在线健康状态(state of health, SOH)的准确预测,但该方法离线阶段模型的准确性对预测结果影响较大。文献[22]利用支持向量机结合鸟群优化算法提升预测精度,但需要集成多种智能算法,计算复杂度较高。文献[23]利用卷积神经网络模型估计锂离子电池 SOH,充电过程中的电压、电流和温度作为模型输入,实现准确的 SOH 估算输出,但其对设备算力要求较高,难以满足大规模储能电站设备监测需求。文献[24]使用放电电压-容量曲线作为模型的输入,并通过网络的卷积层自动进行特征提取过程,只需要预测容量衰减曲线中的3个关键参数,从而保证预测精度的前提下简化了预测算法,但特征提取仍使用卷积神经网络,对设备算力要求较高。可见,在保证预测精度的前提下,减少模型计算量,是数据驱动电池容量预测中的一大挑战。

另一方面,大规模储能电站中电池单体数量庞大,在容量衰退预测中对监测设备和算力要求较高。为降低单体电池的监测设备成本并减少预测模型的计算资源需求,本文提出一种适用于大规模

储能电站的二值化神经网络(binary neural network, BNN)电池容量衰退预测方法。在麻省理工学院(massachusetts institute of technology, MIT)公开数据集上的验证结果表明,与传统神经网络模型相比,本文提出的BNN模型能够在保持预测精度的同时,能大幅提升预测效率,降低计算资源需求,该方法的主要贡献和创新点如下:

1)提出一种低算力需求的电池容量衰退预测模型。在文献[24]的基础上,通过对神经网络权值和激活函数二值化处理,可减少模型参数和计算量,进而提升预测速度并降低硬件成本,为大规模储能系统储能电站、或对计算资源和成本敏感的电池容量预测场景提供更为经济有效的解决方案;

2)引入累积分布函数与双线性方程结合的预测方法,利用累积分布函数反向求解关键参数,并将其代入双线性方程进行容量衰减预测,使得预测过程更加简化和高效。在保证预测精度不显著下降的前提下,显著减少参数数量和计算资源需求,提升计算效率。

1 电池容量衰退在线预测架构

电池容量衰退曲线是指电池使用过程中,电池容量随时间的变化情况。通过预测容量衰退曲线,可以优化电池管理系统,优化电池性能,延长使用寿命。电池容量衰退曲线一般可以通过双线性方程^[15]表示为

$$q = m_0 n + (m_f - m_0) \delta \ln \left(\frac{e^{n/\delta} + e^{N_k/\delta}}{1 + e^{N_k/\delta}} \right) \quad (1)$$

式中, q 为放电容量损失; n 为循环次数; m_0 为初始斜率; N_k 为翻转周期; δ 为翻转宽度; m_f 为失效斜率。

针对电池容量衰退估算问题,本文提出基于BNN的电池容量衰退在线预测架构,如图1所示。由于储能电站出于安全考虑普遍采用新电池,而新电池初期无明显衰退特征,所提方法需在电池运行100次循环周期后采集数据,方可保证容量衰退预测的有效性。图1中,先根据已有公开数据集离线进行训练,建立BNN预测模型;然后,将在线得到前100个循环周期的放电容量 Q -电压 V 数据经等压处理后得到二维数据,输入到训练好的BNN模型,输出翻转周期、翻转宽度和失效斜率等参数累积分布函数值,再分别代入各参数的累积分布函数,通过二分法反向求解得到对应的关键参数;最后,将参数代入双线性方程得到电池容量衰退曲线。




图1 基于BNN的电池容量衰退在线预测架构

Figure 1 Architecture of online battery capacity degradation prediction based on BNN

2 电池容量衰退曲线的关键参数

2.1 试验数据集

本文采用MIT公开的锂离子电池循环数据集,电池为A123系统公司标准产品,包含178个电池测试周期数从147到2 236不等。电池额定容量为1.1 A·h,额定电压为3.3 V,充、放电循环试验在30℃的恒定环境温度下进行,采用先恒流、后恒压的快速充电策略。电池分别使用108个组电池数据作为训练数据集,35个组电池数据作为验证数据集,35个组电池数据作为预测数据集。

2.2 容量衰退曲线的关键参数求解

式(1)中计算放电容量损失,需要已知初始斜率 m_0 、翻转周期 N_k 、翻转宽度 δ 、失效斜率 m_f 这4个关键参数。其中,翻转周期 N_k 定义为电池放电过程中,放电速率从最大值下降到一半所需的循环次数;翻转宽度 δ 定义为电池翻转周期内,放电速率的变化范围。由这些定义可以将翻转宽度 δ 设定为常数50,则式(1)中的关键参数可以简化为3个。

建立电池训练数据的初始斜率、翻转周期和失效斜率直方图,如图2所示。根据这些参数的直方图,设定0.05的显著性水平情况下,利用柯尔莫哥洛夫-斯米尔诺夫检验分别完成初始斜率、滚动周期和失效斜率的统计特性检验。

初始斜率概率密度符合柯西分布,其累积分布函数为

$$f(m_0, x_0, \gamma) = \frac{1}{\pi \lambda \left(1 + \left(\frac{m_0 - x_0}{\gamma} \right)^2 \right)} \quad (2)$$

式中, x_0 为分布峰值位置的位置参数; γ 为最大值一半处的一半宽度的尺度参数。




图2 初始斜率、翻转周期和失效斜率直方图

Figure 2 Histograms of initial slope, flip cycle, and failure slope

翻转周期概率密度符合瑞利分布,其累积分布函数为

$$f(N_k, \sigma_N) = \frac{N_k}{\sigma_N^2} \exp\left(-\frac{N_k^2}{2\sigma_N^2}\right), N_k > 0 \quad (3)$$

式中, σ_N 为瑞利分布的方差。

失效斜率概率密度符合对数正态分布,其累积分布函数为

$$f(m_f, \mu_m, \sigma_m) = \frac{1}{\sigma_m m_f \sqrt{2\pi}} \exp\left[-\frac{(\ln m_f - \mu_m)^2}{2\sigma_m^2}\right], m_f > 0 \quad (4)$$

式中, μ_m 为对数正态分布的期望值; σ_m 为对数正态分布的标准差。

通过二值化卷积神经网络模型得到初始斜率、翻转周期和失效斜率的累积分布函数预测值,在此基础上,本文采用二分法代入上述累积分布函数求解关键参数。二分法是一种通过迭代求解方程式根近似值的算法,具有算法简单,线性收敛的优点。结合Python安装的sympy库求解器分别代入累积分布函数式(2)~(4),可以较精确求解出衰退曲线中翻转周期、翻转宽度和失效斜率3个未知参数。

3 BNN预测模型

3.1 BNN基本原理

随着 ChatGPT 卷积神经网络为代表的通用型人工智能模型快速进步,模型使用多层卷积神经网络,并拥有高达上千亿个参数,也需要更大规模的存储和运算能力,成本相当昂贵。但低成本的小型应用设备中,其拥有的存储和运算资源极为有限,为使用多层卷积神经网络带来了挑战^[15]。BNN是解决该问题的一种方法,通过减少的内存和计算需求,同时仍然提供与全精度卷积神经网络模型相似的功能。2016年,Courbariaux 等人首次提出BNN,在网络中使用二进制权重和激活计算参数梯度,并且推理和反向传播训练期间都使用这些二进制值,最后在多个公开数据集上测试,都取得了接近全精度卷积神经网络最佳测试结果^[25]。该模型将32位全精度的权值改为1比特二值化数据,不仅理论上将模型规模大幅度缩小,而且速度有较大提升。

BNN模型类似于传统的卷积神经网络,由单个输入层、多个卷积层、多个池化层、多个归一化、多个全连接层和单个输出层构成,但其中的卷积层和

全连接层为二值化处理。二值化处理是将全精度变量转换为+1或-1的2个数值,需要使用二值化函数,目前主要采用确定性二值化和随机二值化2种^[26]。第1种确定性二值化函数为

$$x^b = \text{sign}(x) = \begin{cases} +1, & x \geq 0 \\ -1, & \text{其他} \end{cases} \quad (5)$$

式中, x^b 为二值化变量(权重或激活); x 为全精度变量。

第2种为随机性二值化函数为

$$x^b = \begin{cases} +1, & \text{当概率为 } p = \sigma(x) \\ -1, & \text{当概率为 } 1 - p \end{cases} \quad (6)$$

式中, σ 为sigmoid($\cdot$)函数,其表达式为

$$\sigma(x) = \text{clip}\left(\frac{x+1}{2}, 0, 1\right) = \max\left(0, \min\left(1, \frac{x+1}{2}\right)\right) \quad (7)$$

其中,clip($\cdot$)为截断函数。

由于确定性二值化函数实现起来简单易行,而随机性二值化函数需由硬件生成随机位、实现困难,因此模型普遍采用确定性二值化函数。

3.2 BNN结构及参数设置

本文所使用的BNN具体结构及参数设置如表1所示。

表1 用于预测关键参数概率的BNN结构

Table 1 BNN structure for predicting the probability of key parameters

输入	输出	第1层	第2,3层	第4层	第5,6层	第7,8层	第9,10层	第11层	第12,13层	第14层	第15,16层	第17层
容量	锂电池容	100×	Binary-		Binary-							
Q-电压	量衰退曲	100)Q-V	Conv-8@1×	MaxPool	Conv-16@	Conv-32@1×	Conv-16@3×	MaxPool	Batch-		Linear-6&	Linear-
V矩阵	线的关键	矩阵输	1 & Binary-	2d@3×3	5×5 & Bina-	1 & MaxPool2	3 & Binary-	2d@3×3	Norm2d-16	FC	Batch-	3 &
	参数	入数据	Conv-16@		ryConv-32	d@3×3	Conv-16@1×1		& ReLU		Norm1d-6	Sigmoid
			1×1		@1×1							

表1中:第1层是结构为100×100的输入层,其中行100代表单个电池前一百个循环周期的容量充放电曲线,列100代表单次充放电曲线;第2层与第3层为包含1个滤波器的二值化卷积层,用于提取输入数据的特征信息。这两层中的滤波器分别包含8、10个1×1大小的卷积核;第4层为包含1个滤波器的Maxpool2d池化层,池化层滤波器用于提取二值化卷积层滤波器的特征信息,以在维持主要信息的同时将特征信息整合,进而降低网络参数。

Maxpool2d池化层滤波器覆盖3×3的范围,同时提取该区域内的最大值作为主要信息,并将其输出。第5、6、7层与第2、3层类似,卷积核的个数分别变为16、32、32个,第5层卷积核的大小变为5×5;第8层与第4层类似;第9、10层与第2、3层类似,

卷积核的个数变为16个,第9层卷积核的大小变为3×3;第11层与第4层类似;第12层为BatchNorm2d层,16代表需要处理的特征数量,实质为归一化层,用于对二值化卷积层输出的多维数据进行归一化处理,以确保网络性能的稳定性;第13层为Relu层;第14层为FC层,其本质是全连接层,主要用于将卷积层和池化层中的多维数据结构转换为一维数据结构,充当二值化卷积层和池化层与全连接层之间的过渡结构。第15层为全连接层,包含6个隐藏节点,并通过第16层BatchNorm2d层后输出;第17层为全连接层,其总共包含3个隐藏节点,并通过第17层sigmoid层后输出初始斜率、翻转周期和失效斜率等3个关键参数的概率密度,sigmoid($\cdot$)主要用于将上一全连接层的输出值限制在0到1内。

3.3 BNN参数优化

为了训练二值权值,本文只在正向传递和反向传播阶段对权值进行二值化处理^[26],即

$$W_B = \text{sign}(W_R) \quad (8)$$

假设符号函数 $a = \text{sign}(u)$ 所需梯度^[27]为 $\frac{dC}{du}$,

则有

$$\text{est}\left(\frac{dC}{du}\right) = \frac{dC}{da} \cdot \frac{d\text{sign}(u)}{du} = \begin{cases} \frac{dC}{da}, & -1 \leq u \leq 1 \\ 0, & \text{其他} \end{cases} \quad (9)$$

式(8)、(9)中, W_B 为实值权重; W_R 为二值化权重; $\text{est}(\cdot)$ 为梯度的估计值。

式(10)保留了梯度的信息,但当 u 过大时,会由于梯度性能显著下降而取消。导数 $d\text{sign}(u)/du$ 也可以看作是梯度通过 HTanh 的传播^[27],它作为分段线性激活函数的表达式如下:

$$\text{est}(\text{sign}(x)) = \text{HTanh}(x) = \begin{cases} +1, & x > 1 \\ x, & -1 \leq x \leq 1 \\ -1, & x < -1 \end{cases} \quad (10)$$

二值化梯度被反向传播上的恒等式所取代^[28]:

$$\Phi(L, W_R) = \frac{\partial L}{\partial W_B} \approx \frac{\partial L}{\partial W_R} \quad (11)$$

式中, L 为输出端的损失; Φ 为梯度。

二值化神经网络的权值训练过程中,先对每一层的权重进行二值化。再在前向传播使用二值权重及其相应的缩放因子;在反向传播中,梯度根据估计的权重计算。最后,通过更新规则对参数和学习率进行更新。

3.4 预测流程

本文所提出的 BNN 模型,将锂电池放电的容量-电压作为输入信号,信号采样为锂电池前 100 次放电周期,而每个周期内考虑放电引起上限电压跌落的 3.5 V 和电压下限 2.0 V 之间等电压取 100 个采样点,因此输入为 100×100 的二维数据,输出为描述锂电池容量衰退曲线的初始斜率、翻转周期和失效斜率 3 个参数的累积分布函数值。当 BNN 完成离线训练后,将锂离子电池满充电后,再放电获取的容量-电压 100×100 个采样值,输入完成训练的二值化神经网络中,便能获取当前锂电池衰退曲线的 3 个关键参数的累积分布函数值。基于 BNN 的电池容量衰退关键参数累积分布函数值预测流程如图 3 所示。图 3 中各步骤如下:

1) 试验数据。首先保证锂电池快速充满电,再记录放电过程中 100 个等压点的容量-电压测量值;重复上述过程直到得到 100 次锂离子电池放电数据。

2) 搭建 BNN 结构并设置网络参数。搭建 17 层的 BNN,各层结构如表 1 所示。

3) 训练 BNN。通过优化算法实现二值化权值参数的学习和更新,直至目标函数满足要求。

4) 估算锂离子电池关键参数累积分布函数值。将锂电池充满电后,放电过程中所采集容量-电压的 100×100 二维数据输入训练后的 BNN 并输出初始斜率、翻转周期和失效斜率的累积分布函数值估算值,与通过评价函数进行分析,从而评价 BNN 的有效性。




图3 基于BNN的电池容量衰退关键参数累积分布函数值预测

Figure 3 Prediction process diagram of cumulative distribution function values of key parameters for battery capacity degradation based on BNN

4 试验与分析

为了验证本文所提出的基于 BNN 的锂电池容量衰退曲线预测的有效性,本节在 MIT 的锂电池公开数据集基础上进行电池容量退化预测,并与基于 CNN 的锂电池容量衰退曲线预测方法进行对比。

4.1 实验设置

试验硬件环境为 Intel i5-8250U CPU @1.60 GHz 处理器,16 GB 内存,NVIDIA 集成显卡。软件环

境为 Pycharm, 采用 Python 语言编写程序, 框架为 pytorch, 利用其搭建神经网络模型。

试验中所使用的 BNN 结构包含多个层次, 具体包括输入层、7 个经过二值化的卷积层、3 个 Max-pool2d 池化层、2 个 BatchNorm2d 批量归一化层、3 个线性层、1 个 Relu 激活层以及 1 个 Sigmoid 输出层。具体网络结构的详细参数见文 2.2。建立 BNN 后, 为了训练网络参数, 选择最小化平均绝对误差 (mean absolute error, MAE) 作为优化目标。为了实现这一目标, 使用 Adam 优化器, 设置学习率为 0.000 6, 并将批量大小设定为 18。试验进行了 100 次迭代以确保网络充分学习。由于网络内部已经包含了归一化层, 因此在 BNN 训练之前无须对样本数据进行额外的归一化处理。为了量化描述锂电池容量衰减曲线预测方法的性能, 采用 MAE 作为性能评价指标。

4.2 锂电池数据处理

试验数据为 MIT 的锂电池公开数据集, 提取锂电池前 100 个周期的放电曲线 (Q - V) 作为 BNN 模型原始输入数据。并将输入数据排列为 100×100 矩阵, 表示 100 个周期内在 2.0 V 和 3.5 V 之间的 100 个等距端电压值下的容量值, 如图 4 所示。

Cycles	1					100
1	$Q_{2.0V}$	..	..	..	..	$Q_{3.5V}$
2	$Q_{2.0V}$	..	..	..	..	$Q_{3.5V}$
3	$Q_{2.0V}$	..	..	..	..	$Q_{3.5V}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
99	$Q_{2.0V}$	...	...	...	...	$Q_{3.5V}$
100	$Q_{2.0V}$	...	...	...	...	$Q_{3.5V}$

图 4 100×100 的电池放电容量-电压矩阵

Figure 4 100×100 discharge capacity-voltage matrix of battery

输入 BNN 模型前, 使用 z 分数方法对输入矩阵进行标准化, 将不同值映射为颜色, 可以表示为图像颜色图, 如图 5 所示, 以更清楚地呈现数据的变化趋势和分布特性。




图 5 输入数据矩阵的图像颜色


Figure 5 Image color map of input data matrix

4.3 试验结果


1) 测试结果。通过训练好的模型对测试集的 35 个电池进行预测, 分别选取其中 4 个不同预测精度的电池, 其容量衰减预测曲线和实测曲线如图 6 所示。在本文模型测试数据集中, 120 号电池预测精度最高, MAE 为 0.77%; 而 55 号电池预测精度最低, MAE 为 3.39%; 120 号电池和 137 号电池预测精度位于该值区间。




(a) 120 号锂电池



(b) 163 号锂电池



(c) 33 号锂电池



(d) 55 号锂电池

图 6 测试集部分电池容量衰退曲线

Figure 6 Capacity degradation curves of some batteries in the test set

由图6锂电池容量衰退曲线可知,锂电池容量衰退曲线预测误差均较小,最大误差值不超过3.39%,且所选取的4个锂电池测试数据上的误差平均值为2.11%,实现了锂电池容量曲线的准确预测。

2) 方法对比。基于BNN与卷积神经网络(convolutional neural network, CNN)的锂电池容量衰退曲线预测性能评估结果如表2所示。对比可知, BNN模型与CNN模型的精度基本相当,但BNN的平均预测时间减少22.37%,且BNN中可训练参数的数量相较于CNN减少了48.9%。

表2 基于BNN与CNN的锂离子电池容量衰退曲线预测性能评估结果

Table 2 Performance evaluation results of capacity degradation curve prediction for lithium-ion batteries based on BNN and CNN

方法	电池编号	MAE/%	时间/s	参数数量
BNN	120	0.77	97.38	21 912
	163	1.80	88.66	
	33	2.46	96.51	
	55	3.39	90.80	
CNN	120	0.91	138.01	42 899
	163	1.26	117.67	
	33	2.51	107.76	
	55	3.03	117.49	

5 结语

本文提出了一种基于BNN的电池容量衰退预测方法。通过在MIT公开数据集上的试验验证,与传统CNN模型相比,该方法在保证预测精度的前提下,模型参数数量减少了48.9%,预测速度提升了22.37%。本文提出的方法具有如下实际意义:

1) 降低电池容量衰退预测对计算资源的需求:通过将卷积运算和权重变量进行二值化处理,显著减少了预测模型的内存占用和计算复杂度,从而降低了设备对计算资源的需求;

2) 提升电池容量衰退预测效率与安全性: BNN模型运算量的减少,有效提升了预测速度,使得在线实时监测电池容量衰退成为可能,为大规模储能电站电池健康管理系统提供一种高效、轻量的预测方法,有助于降低系统硬件成本,并提高电池管理系统的智能化水平,从而有助于提升储能电站的运行效率与安全性。

未来研究将重点解决储能电站实际运行过程中充、放电非完整循环周期下的电池容量预测问题,探索如何在部分非完整循环周期的数据基础上

实现更精准的容量衰退预测,以提升模型的实用性和适应性。

参考文献:

- [1] 黎博,陈民铀,钟海旺,等.高比例可再生能源新型电力系统长期规划综述[J].中国电机工程学报,2023,43(2):555-581.
LI Bo, CHEN Minyou, ZHONG Haiwang, et al. A review of long-term planning of new power systems with large share of renewable energy[J]. Proceedings of the CSEE, 2023, 43(2): 555-581.
- [2] 刘凡,李凤婷,张高航,等.计及循环寿命和运营策略的风电汇集区域储能电站优化配置[J].电力系统保护与控制,2023,51(8):127-139.
LIU Fan, LI Fengting, ZHANG Gaochang, et al. Optimal configuration of storage power stations in a wind power gathering area considering cycle life and operation strategy[J]. Power System Protection and Control, 2023, 51(8): 127-139.
- [3] 鲁南,欧阳权,黄浪卉,等.基于注意力机制和多任务LSTM的锂电池容量预测方法[J].电气工程学报,2022,17(4):41-50.
LU Nan, OUYANG Quan, HUANG Lianghui, et al. Capacity prediction of lithium-ion batteries based on multi-task LSTM with attention mechanism[J]. Journal of Electrical Engineering, 2022, 17(4): 41-50.
- [4] 高金武,贾志桓,王向阳,等.基于PSO-LSTM的质子交换膜燃料电池退化趋势预测[J].吉林大学学报(工学版),2022,52(9):2192-2202.
GAO Jinwu, JIA Zhihuan, WANG Xiangyang, et al. Degradation trend prediction of proton exchange membrane fuel cell based on PSO-LSTM[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(9): 2192-2202.
- [5] 许守平,李相俊,惠东.大规模储能系统发展现状及示范应用[J].电源技术,2015,39(1):217-220.
XU Shouping, LI Xiangjun, HUI Dong. Survey of development and demonstration application of large-scale energy storage[J]. Chinese Journal of Power Sources, 2015, 39(1): 217-220.
- [6] HEIN S, DANNER T, LATZ A. An electrochemical model of lithium plating and stripping in lithium ion batteries [J]. ACS Applied Energy Materials, 2020, 3(9): 8519-8531.
- [7] XIONG R, HUANG J T, DUAN Y Z, et al. Enhanced Lithium-ion battery model considering critical surface charge behavior[J]. Applied Energy, 2022, 314: 118915.
- [8] 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.
- [9] HE J T, BIAN X L, LIU L C, et al. Comparative study of curve determination methods for incremental capacity

- analysis and state of health estimation of lithium-ion battery[J]. *Journal of Energy Storage*, 2020, 29: 101400.
- [10] LI X Y, YUAN C G, LI X H, et al. State of health estimation for Li-Ion battery using incremental capacity analysis and Gaussian process regression[J]. *Energy*, 2020, 190: 116467.
- [11] 王萍, 范凌峰, 程泽. 基于健康特征参数的锂离子电池 SOH 和 RUL 联合估计方法[J]. *中国电机工程学报*, 2022, 42(4): 1523-1534.
- WANG Ping, FAN Lingfeng, CHENG Ze. A joint state of health and remaining useful life estimation approach for lithium-ion batteries based on health factor parameter[J]. *Proceedings of the CSEE*, 2022, 42(4): 1523-1534.
- [12] WU J, CHEN J X, FENG X, et al. State of health estimation of lithium-ion batteries using Autoencoders and Ensemble Learning[J]. *Journal of Energy Storage*, 2022, 55: 105708.
- [13] LOVE C T, VIRJI M B V, ROCHELEAU R E, et al. State-of-health monitoring of 18650 4S packs with a single-point impedance diagnostic[J]. *Journal of Power Sources*, 2014, 266: 512-519.
- [14] LEI Y G, LI N P, GUO L, et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction[J]. *Mechanical Systems and Signal Processing*, 2018, 104: 799-834.
- [15] 董浩, 毛玲, 屈克庆, 等. 基于温度和 SOC 的锂离子电池特征提取及 SOH 估计[J]. *浙江大学学报(工学版)*, 2023, 57(7): 1470-1478.
- DONG Hao, MAO Ling, QU Keqing, et al. Factor extraction and SOH estimation of lithium-ion battery based on temperature and SOC[J]. *Journal of Zhejiang University (Engineering Science)*, 2023, 57(7): 1470-1478.
- [16] 吴欢欢, 邵素霞, 代娟, 等. 锂离子电池 2 种内阻测试方法关联性的研究[J]. *合肥工业大学学报(自然科学版)*, 2023, 46(7): 1003-1008.
- WU Huanhuan, SHAO Suxia, DAI Juan, et al. Study on the correlation of two kinds of internal resistance measurement approaches for lithium-ion battery[J]. *Journal of Hefei University of Technology (Natural Science)*, 2023, 46(7): 1003-1008.
- [17] PAN W J, LUO X S, ZHU M T, et al. A health indicator extraction and optimization for capacity estimation of Li-ion battery using incremental capacity curves[J]. *Journal of Energy Storage*, 2021, 42: 103072.
- [18] 张婷婷, 于明, 李宾, 等. 基于 Wavelet 降噪和支持向量机的锂离子电池容量预测研究[J]. *电工技术学报*, 2020, 35(14): 3126-3136.
- ZHANG Tingting, YU Ming, LI Bin, et al. Capacity prediction of lithium-ion batteries based on wavelet noise reduction and support vector machine[J]. *Transactions of China Electrotechnical Society*, 2020, 35(14): 3126-3136.
- [19] SONG Y C, LIU D T, LIAO H T, et al. A hybrid statistical data-driven method for on-line joint state estimation of lithium-ion batteries[J]. *Applied Energy*, 2020, 261: 114408.
- [20] 韦海燕, 陈孝杰, 吕治强, 等. 灰色神经网络模型在线估算锂离子电池 SOH[J]. *电网技术*, 2017, 41(12): 4038-4044.
- WEI Haiyan, CHEN Xiaojie, LÜ Zhiqiang, et al. Online estimation of lithium-ion battery state of health using grey neural network[J]. *Power System Technology*, 2017, 41(12): 4038-4044.
- [21] 王萍, 弓清瑞, 张吉昂, 等. 一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J]. *电工技术学报*, 2021, 36(24): 5201-5212.
- WANG Ping, GONG Qingrui, ZHANG Ji'ang, et al. An online state of health prediction method for lithium batteries based on combination of data-driven and empirical model[J]. *Transactions of China Electrotechnical Society*, 2021, 36(24): 5201-5212.
- [22] 王雪莹, 赵全明. 基于改进鸟群算法优化最小二乘支持向量机的锂离子电池寿命预测方法研究[J]. *电气应用*, 2020, 39(5): 12-16.
- WANG Xueying, ZHAO Quanming. Research on lithium-ion battery life prediction method based on improved bird swarm algorithm least squares support vector machine[J]. *Electrotechnical Application*, 2020, 39(5): 12-16.
- [23] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池 SOH 估算[J]. *电工技术学报*, 2020, 35(19): 4106-4119.
- LI Chaoran, XIAO Fei, FAN Yaxiang, et al. An approach to lithium-ion battery SOH estimation based on convolutional neural network[J]. *Transactions of China Electrotechnical Society*, 2020, 35(19): 4106-4119.
- [24] SAXENA S, WARD L, KUBAL J, et al. A convolutional neural network model for battery capacity fade curve prediction using early life data[J]. *Journal of Power Sources*, 2022, 542: 231736.
- [25] YUAN C Y, AGAIAN S S. A comprehensive review of binary neural network[J]. *Artificial Intelligence Review*, 2023, 56(11): 12949-13013.
- [26] SIMONS T, LEE D J. A review of binarized neural networks[J]. *Electronics*, 2019, 8(6): 661.
- [27] LIANG S, YIN S Y, LIU L B, et al. FP-BNN: Binarized neural network on FPGA[J]. *Neurocomputing*, 2018, 275: 1072-1086.
- [28] LI Y, BAO Y Y, CHEN W. Fixed-sign binary neural network: an efficient design of neural network for Internet-of-things devices[J]. *IEEE Access*, 2020, 8: 164858-164863.