

引用格式:刘巨,任羽纶,易柏年,等.LSTM-EKF算法实现储能集装箱电芯SOC的优化估计[J].电力科学与技术学报,2024,39(2):198-206.

Citation: LIU Ju, REN Yulun, YI Bonian, et al. Optimal estimation of cell SOC in energy storage container with LSTM-EKF algorithm[J]. Journal of Electric Power Science and Technology, 2024, 39(2): 198-206.

LSTM-EKF 算法实现储能集装箱 电芯 SOC 的优化估计

刘 巨¹, 任羽纶¹, 易柏年¹, 董 哲¹, 余 轶¹, 熊 志¹,
余紫菀², 王映祺², 刘 健²

(1. 国网湖北省电力有限公司经济技术研究院, 湖北 武汉 430061; 2. 武汉工程大学电气信息学院, 湖北 武汉 430073)

摘 要: 储能集装箱是锂电池储能电站的核心设备, 每个集装箱由数千只电芯串并联构成。因此, 对集装箱电芯锂电池荷电状态 (state of charge, SOC) 的准确估计成为表征储能电站运行最核心最基础的参数, 并且为辅助新能源高效并网, 储能系统的工作状态也会相应地呈现随机性、波动性和不确定性, 这对电芯状态估计的准确度提出了更高的要求。为此, 首先基于基尔霍夫定律建立 Thevenin 电池模型, 根据安时积分法列出系统的状态和观测方程, 并且将其状态和观测方程作为扩展卡尔曼滤波 (extended Kalman filtering, EKF) 算法的研究对象。然后利用 EKF 算法对估计值电芯 SOC 更新迭代, 再将 EKF 算法中得到的卡尔曼矩阵和状态变量更新误差值以及 UDDS 工况下的电池数据, 作为长短期记忆 (long short-term memory, LSTM) 神经网络算法的训练数据集, 由此完成 LSTM-EKF 联合算法, 实现对储能集装箱电芯 SOC 的优化估计。该文所提 LSTM-EKF 算法可将电芯 SOC 的误差值降低到 1% 以下。最后对优化算法在储能电站安全运行与监控平台中的应用情况进行介绍。

关 键 词: 储能集装箱; 锂电池 SOC; 扩展卡尔曼滤波; 长短期记忆神经网络; 优化估计

DOI: 10.19781/j.issn.1673-9140.2024.02.022 中图分类号: TM912 文章编号: 1673-9140(2024)02-0198-09

Optimal estimation of cell SOC in energy storage container with LSTM-EKF algorithm

LIU Ju¹, REN Yulun¹, YI Bonian¹, DONG Zhe¹, YU Yi¹, XIONG Zhi¹,
YU Zidan², WANG Yingqi², LIU Jian²

(1. Economic and Technical Research Institute, State Grid Hubei Electric Power Co., Ltd., Wuhan 430061, China;

2. College of Electrical and Electronic Engineering, Wuhan Institute of Technology, Wuhan 430073, China)

Abstract: Energy storage container is the core equipment of a power plant for lithium battery energy storage. Each container is composed of thousands of cells connected in series and parallel. Therefore, the accurate estimation of the state of charge (SOC) of lithium batteries in container cores becomes the core and basic parameter to characterize the operation of a power plant for energy storage. Moreover, in order to assist the new energy to be connected to the grid efficiently, the operating state of the energy storage system is randomness, fluctuation and uncertainty, which requires higher accuracy of the cell state estimation. In this paper, the Thevenin model of battery is firstly established on the basis of the Kirchhoff's circuit laws. The state and observation equations of the system are listed according to the ampere-time integration method, and then as the study object for the extended Kalman filter (EKF) algorithm. The EKF algorithm is used to update and iterate the estimated SOC of battery. The updated error values of the Kalman matrix and state variables derived from the EKF algorithm, and the battery data under UDDS conditions are as a training data set for long-term and short-term memory (LSTM) neural network algorithm. The joint algorithm of LSTM-EKF is thus

收稿日期: 2022-12-14; 修回日期: 2023-03-24

基金项目: 国家科技攻关计划 (2014BAA04B00); 国网湖北经研院科技项目 (B31538222027)

通信作者: 刘 健 (1979—), 男, 博士, 教授, 主要从事电力系统与新能源领域的研究; E-mail: liujian@wit.edu.cn

completed to achieve an optimized estimation of the SOC of batteries in container cores. The SOC error can be reduced to less than 1% by the proposed LSTM-EKF algorithm. The optimization algorithm applied in the safe operation and monitoring platform of energy storage power station is finally introduced.

Key words: energy storage containers; SOC of lithium battery; extended Kalman filter; long-term and short-term memory neural network; optimal estimation

随着“双碳”目标的提出,中国能源产业亟需快速转型,绿色低碳成为能源产业发展的一大重要指标^[1]。因此,以风电、光伏为代表的新能源得到快速发展,在《中国可再生能源发展报告2021》中指出,截至2021年底,中国可再生能源装机突破10亿kW,占全国电力装机的44.8%。2021年风电发电量为5667亿kW时占比6.6%,光伏发电量为3259亿kW时占比4.0%。在“双高”背景下,中国提出并要求在新型电力系统的源、网、荷侧推进储能系统的应用,根据中国能源研究会储能专委会/中关村储能产业技术联盟(China energy storage alliance, CNESA)全球储能项目库的不完全统计,截至2020年底,全球已投运储能项目累计装机规模191.1GW,同比增长3.4%。其中,抽水蓄能的累计装机规模最大,为172.5GW,同比增长0.9%;电化学储能的累计装机规模紧随其后,为14.2GW;在各类电化学储能技术中,锂离子电池的累计装机规模最大,突破10GW大关,达到13.1GW。因此,开展储能电站控制与安全运行方面的研究,具有重要的现实意义。

电化学储能电站是由多个储能集装箱并联构成的。例如,全球首座百兆瓦级分散式控制的华能济南黄台储能电站(100MW/200MW·h)由80套容量为1.25MW/2.5MW·h的储能集装箱构成,每个集装箱由数10个“储能柜”并联构成,1个储能柜由数百只电芯串并联构成,因此,整个集装箱内部包含数千只电芯。将集装箱作为储能电站的最小单元,然后通过对单个集装箱的电压、电流进行检测以完成荷电状态(state of charge, SOC)估计^[2],这样往往会带来较大的误差。因此,非常有必要针对集装箱内的单个电芯进行状态估计,之后将该数据提供给“储能柜”主机,再汇总至“集装箱”,从而得到储能集装箱准确的SOC参数。

储能电站的工作状态与电动汽车、5G电站的蓄电池系统的工作状态有着较大差别,特别是应用在新型电力系统中的储能电站,为了辅助新能源高效并网,完成系统调频、调峰,电站的工作状态更多时

候呈现出随机性、波动性和不确定性,加之储能电站的锂电池在工作时本身也是高复杂的非线性系统^[3-5],仅利用储能集装箱的SOC进行调控,会带来系统SOC误差偏大,电池损伤与寿命缩短,以及系统运行效率降低的问题^[6],这也是行业有待解决的一项痛点。

目前,锂电池SOC估计常用的方法为开路电压法、安时积分法^[7]、基于模型的估算方法^[8]以及基于数据学习的估算方法^[9]。安时积分法和开路电压法由于受到传感器测量误差的影响,以及需要对电池进行长时间的静置,所以很难单独应用于电池SOC的估计;基于模型的估算方法对电池模型依赖较强,而实际电池的工况复杂,很难完全模拟,且模型过于复杂会造成参数难以辨识的问题;基于数据学习的估算方法对数据要求高,数据集的大小以及准确性对其性能有很大的影响。文献^[10]提出了一种自适应的卡尔曼滤波(Kalman filtering, KF)算法,改进二阶RC电路模型以及对噪声进行更新,提高了锂电池SOC精度;文献^[11]基于扩展卡尔曼滤波(extended Kalman filtering, EKF)算法提出了最大相关熵的新算法,在运行时间增加很小的情况下,该算法估计精度和鲁棒性好。虽然KF算法降低了系统的开环风险,但是电池模型无法精确还原电池工作状态特性,由于新型电力系统中的储能装备工作的随机性、波动性会导致观测量频繁突变,使得KF算法的准确性和稳定性下降。文献^[12]基于长短期记忆(long short-term memory, LSTM)神经网络对电池进行SOC估计,利用电池相关测量值(电压、电流和温度)直接映射到电池SOC,一定程度上提高了估算精度。LSTM神经网络虽然简化了电池的建模过程并且保证了算法的鲁棒性,但是忽略了系统的开环风险,对神经网络训练数据有着很高的要求,对于工作状态存在不确定性的系统,其运算精度有待进一步提升。

本文针对KF和神经网络算法的不足,将基于模型和基于数据学习的估算方法结合,联合EKF和LSTM神经网络算法,提出LSTM-EKF算法,用于

估计锂电池的SOC,既能解决EKF算法对电池模型精度要求高、滤波容易发散的问题,又能规避LSTM神经网络算法估计SOC系统的开环风险,可为新型电力系统中储能设备的SOC估计提供一种新的解决办法。

1 电芯模型建立

电芯模型的准确性对SOC估计精确度起到重要作用,由于储能集装箱中集成了数千只电芯,因此,考虑减小计算量的实际情况,电芯模型需要尽量简单并且与实际情况相符。本文在参考Rint、Thevenin^[13]以及双RC^[14]电池模型后,选用Thevenin等效电路模型作为基础,其等效电路如图1所示。




图1 Thevenin锂电池模型

Figure 1 Thevenin model of lithium battery

根据Thevenin锂电池模型,利用基尔霍夫电压电流定理可得:

$$\begin{cases} U_L = U_{oc} - U_2 - IR_1 \\ I = \frac{U_2}{R_2} + C_2 \frac{dU_2}{dt} \end{cases} \quad (1)$$

式中, I 、 U_L 分别为锂电池工作时的电流、电压,可以通过电流表和电压表测得; U_{oc} 为 t 时刻Thevenin等效电路中锂电池的开路电压,可以通过锂电池的SOC确定。

2 电芯模型参数辨识

Thevenin等效电路中 I 和 U_L 可以通过电流表和电压表测得, U_{oc} 是一个关于SOC的函数,需要对 R_1 、 R_2 、 C_2 进行辨识。本文采用离线辨识的方法进行参数辨识^[15],对锂电池进行复合脉冲功率性能(hybrid pulse power characterization, HPPC)测试,以松下CGR18650CH型号的锂电池为例,具体参数指标如表1所示。

HPPC实验步骤:①用恒流恒压的充电方式将锂电池充满,即SOC为100%;②以0.5C(1A)对电流进行放电直至锂电池SOC减少10%;③放电结束后将锂电池静置1h;④重复步骤②、③直到锂电池SOC为0,或者达到放电截止电压时结束实验。通

过HPPC实验可得到不同SOC时刻下的对应 U_{oc} ,如表2所示。

表1 锂电池参数指标

Table 1 Parameter of lithium battery

额定容量/ (mA·h)	额定 电压/V	最大持续 放电电流/A	温度/°C		截止电压/V	
			充电	放电	充电	放电
2 250	3.6	10	10~45	-20~60	4.2	2.6

表2 不同SOC下的 U_{oc}

Table 2 U_{oc} under different SOC V

SOC	U_{oc}	SOC	U_{oc}	SOC	U_{oc}	SOC	U_{oc}
1.0	4.15	0.7	3.82	0.4	3.60	0.2	3.53
0.9	4.05	0.6	0.73	0.3	3.57	0.1	3.44
0.8	3.92	0.5	3.64				

开路电压 U_{oc} 和SOC存在很强的映射关系,因此,得到准确的 U_{oc} 对后续准确估算SOC具有重要意义。在得到不同SOC时刻下的 U_{oc} 后,通过MATLAB中的CFtool拟合工具箱进行数据拟合,得到SOC与 U_{oc} 的拟合曲线,如图2所示。




图2 SOC与 U_{oc} 的拟合曲线

Figure 2 Fitting curve between SOC and U_{oc}

实验结果的局部放大图以及锂电池在放电过程中的电压、电流变化曲线如图3所示,可以看出,电池在放电过程中存在B-C和D-E这2个特殊阶段。B-C阶段:锂电池放电刚开始,电压缓慢下降,此阶段仍然有电流流过回路,此时为零状态响应阶段。D-E阶段:锂电池放电结束,电压缓慢上升,此阶段没有电流流过回路,此时为零输入响应阶段。产生这2个特殊阶段的主要原因是锂电池内部的极化电阻 R_2 导致电压出现“迟滞效应”。A-B和C-D阶段电池的电压发生突变是由锂电池欧姆内阻 R_1 导致的,利用A-B和C-D阶段可以完成对 R_1 的辨识^[16]。由欧姆定律可知:

$$R_1 = \frac{(U_A - U_B) + (U_D - U_C)}{I} \quad (2)$$

式中, U_A 、 U_B 、 U_C 、 U_D 分别为图 3 中 A、B、C、D 点的电压; I 为锂电池的放电电流。




图 3 脉冲放电局部放大示意

Figure 3 Partial amplification of pulse discharge

对于 B-C 的零状态响应阶段:

$$U_L = U_{OC} - IR_1 - IR_2(1 - \exp(-t/\tau)) \quad (3)$$

式中, U_{OC} 、 I 、 R_1 是已知量; $\tau = R_2 \cdot C_2$ 为 RC 回路的时间常数。对 B-C 通过 Matlab 中的 Cftool 拟合工具箱进行拟合, 自定义拟合函数为

$$f(x) = a - b(1 - \exp(-t/c)) \quad (4)$$

其中, a 作为 U_{OC} 、 I 、 R_1 是已知量, R_2 、 τ 分别作为待定系数 b 、 c , 通过 B-C 拟合出系数 b 再根据欧姆定律求出 R_2 。

对于 D-E 的零输入响应阶段:

$$U_L = U_{OC} - IR_1 - U_2 \exp(-t/\tau) \quad (5)$$

式中, U_2 为 RC 回路电压。对 D-E 阶段拟合:

$$f(x) = a - b(\exp(-t/c)) \quad (6)$$

这个阶段拟合出系数 c , 根据 $\tau = R_2 \cdot C_2$ 求出 C_2 。整个实验的参数辨识结果如表 3 所示。

表 3 离线参数辨识结果

Table 3 Offline parameter identification results

SOC	R_1/Ω	R_2/Ω	C_2/F
0.1	0.228 2	0.014 2	3 720.6
0.2	0.227 3	0.014 6	2 226.4
0.3	0.222 9	0.015 8	2 345.6
0.4	0.221 9	0.013 1	2 261.5
0.5	0.232 1	0.012 5	1 592.6
0.6	0.228 5	0.013 3	1 592.8
0.7	0.226 1	0.016 2	1 422.6
0.8	0.221 0	0.017 8	1 286.3
0.9	0.223 0	0.013 2	1 599.6

在完成系统的参数辨识后, 为了验证等效电路模型和参数辨识的准确性, 将已辨识的参数加载到

等效电路模型中, 对等效电路模型加载实验的工况电流, 对比仿真端电压和实验端电压误差, 结果如图 4 所示, 实际测出的电压与模型输出的电压相近, 相对误差最大为 2.5%, 证明该模型有较高精确度。




图 4 电压对比曲线

Figure 4 Comparison curves of voltage

3 电芯 SOC 优化估计方法

结合基于数据驱动和基于锂电池模型的估计方法, 提出 LSTM-EKF 联合算法的锂电池电芯 SOC 优化估计方法, 该算法可以有效提高对锂电池 SOC 估计的精度, 以及系统的鲁棒性和泛化能力。

根据 Thevenin 电池等效模型, 建立第一状态方程和观测方程, 并根据安时积分法建立第二状态方程, 分别为

$$i(t) = \frac{U_2(t)}{R_2} + C_2 \frac{d(U_2(t))}{dt} \quad (7)$$

$$U_L(t) = U_{OC}(t) - U_2(t) - i(t) \cdot R_1 \quad (8)$$

$$S_{oc}(t) = S_{oc}(t_0) - \frac{1}{Q_0} \int_0^t i dt \quad (9)$$

其中, $S_{oc}(t)$ 是 t 时刻 Thevenin 等效电路中锂电池电芯的 SOC 值。根据上述得出的状态方程和观测方程进行离散化处理, 得到 EKF 算法中的系数矩阵为

$$\begin{cases} A = \begin{bmatrix} 1 & 0 \\ 0 & e^{-\Delta t/R_2 C_2} \end{bmatrix} \\ B = \begin{bmatrix} -\Delta t/R_2 C_2 \\ R_2(1 - e^{-\Delta t/R_2 C_2}) \end{bmatrix} \\ C = \begin{bmatrix} \frac{\partial U_{OC}(k)}{\partial S_{oc}} & -1 \end{bmatrix} \\ D = -R_1 \end{cases} \quad (10)$$

3.1 EKF 算法

KF 及其扩展的改进型算法是对线性常系统状态估计的最优化递推估计方法。对于系统内部无法直接测量的状态变量进行估计, EKF 是在 KF 基础上进行扩展的算法^[17]。KF 算法系统的状态和观测方程为

$$\begin{cases} x_k = Ax_{k-1} + Bu_{k-1} + w_{k-1} \\ y_k = C_k x_k + Du_k + v_k \end{cases} \quad (11)$$

式中, x 为系统状态变量; u 为系统输入观测量; y 为系统输出观测量; w 、 v 均为系统噪声。

在基于 EKF 算法估计 SOC 中, 系统输入锂电池工作电流, 输出锂电池端电压, 状态量即为估计量为锂电池电芯的 SOC。首先确定状态方程和协方差的初始值, 然后求出状态变量的估计值 \hat{x}_k 、协方差估计值 P_k 以及卡尔曼增益矩阵 K_k , 随后根据 K_k 调节实际的观测值, 以得到更新后的状态变量的估计值, 最后将得到的估计值加入 EKF 算法中迭代更新。EKF 算法流程为

$$\begin{cases} \hat{x}_0 = E(x_0) \\ p_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T] \\ \hat{x}_k = A\hat{x}_{k-1} + Bi_{k-1} \\ p_k = Ap_{k-1}A^T + w \\ K_k = p_k C_k^T (C_k p_k C_k^T + v)^{-1} \\ \hat{x}_{k+1} = \hat{x}_k + K_k e \\ p_{k+1} = (I - K_k C_k) p_k \\ \hat{x}_0 = \hat{x}_{k+1} \\ p_0 = p_{k+1} \end{cases} \quad (12)$$

式中, $E(*)$ 为期望, I 为单位矩阵; SOC 的初始值设为 1, 极化电压 U_2 设为 0, 协方差的初始值 P_0 设为 1; w 、 v 分别为系统观测和系统输出噪声, w 、 v 的取值均为 0.5; e 为端电压输出观测误差。

3.2 LSTM-EKF 算法设计

由于储能电站的锂电池工作状态也呈现随机性、波动性和不确定性, 为了更好地适应该状态, 本文选用 LSTM 神经网络。经过 EKF 算法的迭代估计, 得到初步估计的 SOC 值, 以及在 EKF 算法中状态变量的更新误差和卡尔曼增益矩阵建立的时序性数据集。

LSTM 是循环神经网络 (recurrent neural network, RNN) 变体的一种, RNN 的缺点是序列中稳定性低, 在反向扩散过程中很容易发生梯度消失和梯度爆炸^[18]。LSTM 具有所有 RNN 都拥有的记忆能力, 并且适用于学习长期依赖, 存储单元代替普通隐藏节点, 缓解许多时间步长后的梯度消失或者爆炸问题^[19-20]。本文中每个 LSTM 单元都包括存储历史输入数据的存储器 and 用于控制时间 k 时输入数据、输出状态和内部隐藏状态之间信息流的门控机制。LSTM 单元结构如图 5 所示, 可知 LSTM 单元结构^[21] 包含输入门、控制门、遗忘门和输出门。输

入门处理并传递输入数据; 控制门将单元状态从 C_{k-1} 更新到 C_k ; 遗忘门决定从历史内存中应忽略哪些信息; 输出门最终生成输出并更新隐藏状态 h_{k-1} 。计算公式为

$$\begin{cases} i_k = \text{sigmoid}(W_{xi}x_k + W_{hi}h_{k-1} + b_i) \\ f_k = \text{sigmoid}(W_{xf}x_k + W_{hf}h_{k-1} + b_f) \\ c_k = f_k c_{k-1} + i_k \tanh(W_{xc}x_k + W_{hc}h_{k-1} + b_c) \\ o_k = \text{sigmoid}(W_{xo}x_k + W_{ho}h_{k-1} + b_o) \\ h_k = o_k \tanh(c_k) \end{cases} \quad (13)$$

式中, W 为权重, b 为偏置; i 、 f 、 o 为内部激活变量; x 、 h 分别为输入数据和输出状态; sigmoid 函数将元素值变换为 $[0, 1]$ 的非线性变换, 一旦门的值接近于 0, 数据将会被丢弃; tanh 函数将元素值变换为 $[-1, 1]$ 的非线性变换, tanh 函数作为激活函数, 在二阶导数归零之前可以在很长的范围内保持稳定, 有效防止梯度消失。




图 5 LSTM 单元结构

Figure 5 Structure of LSTM unit

在实验开始前, 对前期的数据集进行预处理, 处理后的数据是浮点型数据, 由于每个参数都处于不同的取值范围, 所以要将每个参数的数据进行标准化处理^[22]。数据标准化处理是一种线性变换, 将数据集处于不同范围的数据值映射到 $[0, 1]$, 其公式为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (14)$$

式中, x^* 为数据映射后的值; x_{\min} 、 x_{\max} 为数据最小、最大值。

本实验中设置损失函数来衡量测试模型预测精度, 采用平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean squared error, RMSE) 验证并预测模型性能^[23]。损失函数计算为

$$e_{\text{MAE}} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (15)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (16)$$

在进行锂电池 SOC 估计时, 需要根据锂电池在不同工况下的标准充放电数据对 SOC 进行估计。目

前,中国、欧洲和美国均发布了相关的工况参数依据,主要包括联合国欧洲经济委员会(economic commission for Europe,ECE)汽车法规,城市道路循环工况(urban dynamometer driving schedule,UDDS)等。考虑储能电站放电过程与UDDS标准的循环工况近似,故本项目采用MATLAB软件ADVISOR中的UDDS工况曲线作为锂电池SOC估计数据来源。

在 LSTM 神经网络中,以 UDDS 工况数据、EKF 算法中卡尔曼矩阵和状态变量更新误差值的输入层和以 EKF 算法中 SOC 补偿值的输出层作为训练数据集,一方面扩大 LSTM 神经网络数据集,另一方面保持数据集与 SOC 的高度相关性。然后设置 2 层 LSTM 的隐藏层,每层节点数分别为 256、128 个,并且在 LSTM 隐藏层后添加 2 个 Dropout 层^[24-25],概率设置分别选择 0.3、0.2,以防止网络过拟合。LSTM 神经网络结构如图 6 所示。最终得到 LSTM-EKF 算法估计的 SOC 值,LSTM-EKF 算法流程如图 7 所示。




图 6 LSTM 神经网络结构

Figure 6 Structure of LSTM neural network

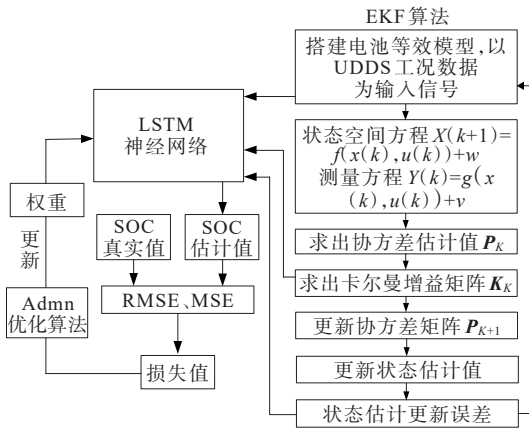



图 7 LSTM-EKF 算法流程

Figure 7 Flowchart of LSTM-EKF algorithm


4 结果验证

完成理论研究后在 MATLAB 软件中搭建仿真

模型,本文研究的核心算法在模型中采用软件编程嵌入的方式实现,并按照图 7 所示流程完成电芯的参数辨识以及 SOC 估算。输入信号为 UDDS 工况下的电压、电流数据如图 8 所示。根据 EKF 算法,搭建 EKF 状态预测、增益矩阵、协方差以及状态更新模块,最后得到由 EKF 算法估计的 SOC 值。以 UDDS 工况数据、EKF 算法卡尔曼矩阵、状态变量更新误差值和 EKF 算法 SOC 补偿值作为数据集,在 LSTM 神经网络中,经过 300 次的迭代完成网络训练, RMSE 曲线如图 9 所示,可以看出,当迭代次数为 50 次时,误差已经达到稳定,且维持在 0.02 以下。



(a) 电压



(b) 电流

图 8 UDDS 工况下锂电池电压、电流数据

Figure 8 Voltage and current result of lithium cell under UDDS condition




图 9 RMSE 曲线

Figure 9 RMSE curve

EKF、LSTM 与 LSTM-EKF 算法得到的电芯 SOC 精度对比如图 10 所示,可以看出,随着仿真时间的增加,电芯的 SOC 值持续减小,在不同系统噪声下,LSTM-EKF 相比 EKF、LSTM 算法精度更高,更接近电芯的实际 SOC 值。不同算法得到的电芯 SOC 值与实际 SOC 值的误差对比如图 11 所示,可以看出,LSTM-EKF 相比 EKF、LSTM 算法的误差进一步减小。




图 10 不同算法下锂电池 SOC 值精度的对比

Figure 10 SOC accuracy comparison of lithium battery between LSTM-EKF and EKF




图 11 不同算法的 SOC 误差对比

Figure 11 SOC error comparison of lithium battery between LSTM-EKF and EKF

对电芯 SOC 估计波形按照式(15)、(16)进行计算,得到电芯 SOC 估计的 RMSE 和 MAE,如表 4 所示,当本文算法中仅使用 LSTM 算法时,得到的误差结果与文献[26]中误差结果近似,为 1% 左右;当本文采用 LSTM-EKF 算法时,不同系统噪声下误差可以得到进一步的缩小。

表 4 误差对比结果

Table 4 Comparison results of error %

系统噪声	LSTM-EKF		LSTM		EKF	
	RMSE	MAE	RMSE	MAE	RMSE	MAE
Q=R=1.0	0.079	0.085	1.35	1.05	2.93	2.15
Q=R=0.5	0.064	0.070	1.21	0.88	1.26	1.02

在完成以上理论分析与算法实现后,本项目构建了实验系统,如图 12(a)所示,对储能集装箱中的

储能柜进行模拟,系统功率为 5 kW/10 kW·h,该平台以储能集装箱中最基本的电柜单元结构为标准。在每个电柜中设置 2 个并联的电池箱,每个电池箱由 8 个额定电压为 3.2 V 的单体电芯串联构成,每个电池箱单独配置 BMS 系统,锂电池组通过 PCS 实现能量的双向流动控制。实验系统的硬件实物如图 12(b)所示,BMS 的核心处理器为 STM32F103 单片机,配置有 2 路隔离 CAN 通信通道以及相应的 AD、IO 端口。在该硬件电路上运行本项目的 LSTM-EKF 算法,采集电压、电流以及计算得到的 SOC 数值,然后通过 CAN 总线按照实际系统运行方式,将电芯以及储能柜的信息上传至监控平台进行显示。

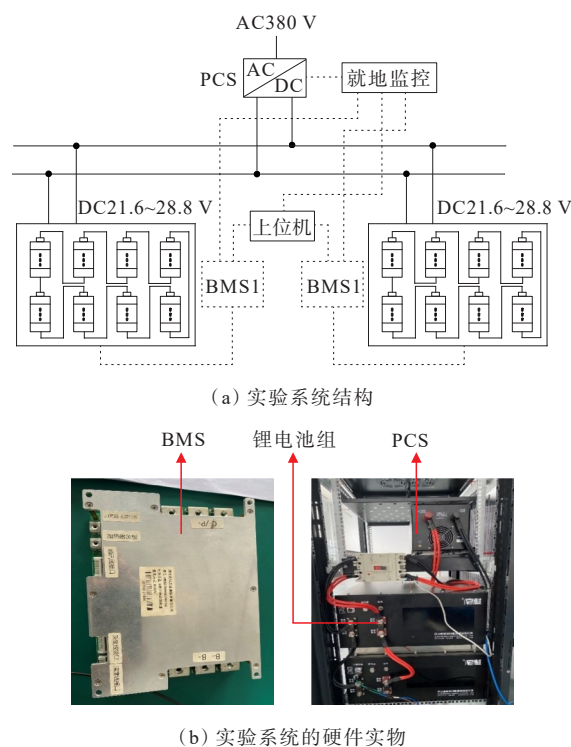


图 12 实验系统总体框架

Figure 12 Overall framework of experiment system

储能电站监控平台主界面如图 13(a)所示,主界面具备完成整个储能电站所有储能集装箱的运行状态监控以及故障预警等功能。储能电站中单台储能集装箱信息界面如图 13(b)所示,其中包括集装箱内每个储能柜和电芯的电压、电流以及经过 LSTM-EKF 算法计算得到的 SOC 数据。

总的来说,实验结果证明了 LSTM-EKF 算法和程序的正确性,以及方案整体框架的可行性。未来,项目将会继续融入储能集装箱运行管理与安全防护中的热失控管理,增加消防预警、电池关键参数等功能,为进一步提高储能系统的安全稳定性提供理论与技术支持。



(a) 储能电站监控平台主界面



(b) 单台储能集装箱信息界面

图 13 锂电池储能系统实物

Figure 13 Physical diagram of lithium battery energy storage system

5 结语

随着“双碳”目标的提出,以风电、光伏为代表的新能源得到快速发展,为了保证“双高”背景下电力系统的安全稳定运行能力,以锂电池为储能元件的储能电站得到了广泛应用,而锂电池储能电站中每个储能集装箱包含数千只电芯,电芯 SOC 成为表征储能电站运行最核心最基础的参数。此外,储能电站的工作状态与电动汽车、5G 电站的蓄电池系统的工作状态又有着较大差别,更多呈现随机性、波动性和不确定性,使其状态估计的难度增加,因此,非常有必要针对以上问题展开研究。

本文结合实际提出了 LSTM-EKF 算法,用于完成储能电站储能集装箱中的锂电池的 SOC 优化估计,其主要特点和创新包括:

1) LSTM-EKF 算法将模型和数据训练预测法相结合,首先利用 EKF 算法对 SOC 进行初步估计,为 LSTM 算法提供与 SOC 值高度相关的参数、状态变量的更新误差和卡尔曼增益矩阵,扩大了 LSTM 神经网络的训练数据集,提高了算法的精度和预测的准确性;

2) LSTM-EKF 算法一方面可以解决 EKF 算法对电池模型精度要求高、滤波容易发散的问题,规避神经网络算法估计 SOC 系统的开环风险;另一方面又可有效避免单一 LSTM 算法的开环风险,并

且防止 EKF 观测量的频繁突变,从而提高模型预测法的鲁棒性;

3) LSTM-EKF 算法适合于处理和预测数据中间间隔和延时时间较长的事件,该算法可以更好地用于完成储能装置在间断工作状态下的锂电池 SOC 估计,为提高整个储能电站 SOC 的预测精度和准确性提供一种有效的解决办法。

参考文献:

[1] 赵冬梅,徐辰宇,陶然,等.多元分布式储能在新型电力系统配电侧的灵活调控研究综述[J].中国电机工程学报,2023,43(5):1776-1799.
ZHAO Dongmei, XU Chenyu, TAO Ran, et al. Review on flexible regulation of multivariate distributed energy storage on distribution side of new power system[J]. Proceedings of the CSEE, 2023,43(5):1776-1799.

[2] 黎冲,王成辉,王高,等.锂电池 SOC 估计的实现方法与性能对比[J].储能科学与技术,2022,11(10):3328-3344.
LI Chong, WANG Chenghui, WANG Gao, et al. Review on implementation method analysis and performance comparison of lithium battery state of charge estimation [J]. Energy Storage Science and Technology, 2022, 11 (10):3328-3344.

[3] 庞辉,郭龙,武龙星,等.考虑环境温度影响的锂离子电池改进双极化模型及其荷电状态估算[J].电工技术学报,2021,36(10):2179-2189.
PANG Hui, GUO Long, WU Longxing, et al. An improved dual polarization model of Li-ion battery and its state of charge estimation considering ambient temperature[J]. Transactions of China Electrotechnical Society,2021,36 (10):2178-2189.

[4] 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 Juping, JIANG Ling, ZHANG Xinsong, 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.

[5] 李正力,李肖辉,王京,等.锂离子电池储能电站热失控预警与防护研究进展[J].高压电器,2024,60(1):87-99.
LI Zhengli, LI Xiaohui, WANG Jing, et al. Research progress on thermal runaway warning and protection of lithium-ion battery in energy storage power station[J]. High Voltage Apparatus, 2024, 60(1):87-99.

[6] 张江丰,苏焯,孙坚栋,等.电网侧电化学储能电站 AGC 控制策略优化及试验分析[J].电力科学与技术学报, 2022,37(2):173-180.
ZHANG Jiangfeng, SU Ye, SUN Jiandong, et al. Optimization and test analysis of AGC control strategy for the grid-side electrochemical energy storage power

- station[J]. *Journal of Electric Power Science and Technology*, 2022,37 (2): 173-180.
- [7] 王义军,左雪. 锂离子电池荷电状态估算方法及其应用场景综述[J]. *电力系统自动化*,2022,46(14):193-207.
WANG Yijun, ZUO Xue. Review on estimation methods for state of charge of lithium-ion battery and their application scenarios[J]. *Automation of Electric Power Systems*, 2022,46 (14): 193-207.
- [8] MENG J, RICCO M, LUO G, et al. An overview and comparison of online implementable SOC estimation methods for lithium-ion battery[J]. *IEEE Transactions on Industry Applications*,2018,54(2):1583-1591.
- [9] LIPU M S H, HANNAN M A, HUSSAIN A, et al. Data-driven state of charge estimation of lithium-ion batteries: algorithms, implementation factors, limitations and future trends[J]. *Journal of Cleaner Production*, 2020, 277: 124110.
- [10] XIONG R, GONG X, MI C C, et al. A robust state-of-charge estimator for multiple types of lithium-ion batteries using adaptive extended Kalman filter[J]. *Journal of Power Sources*, 2013, 243(6):805-816.
- [11] 巫春玲,胡雯博,孟锦豪,等. 基于最大相关熵扩展卡尔曼滤波算法的锂离子电池荷电状态估计[J]. *电工技术学报*, 2021, 36(24):5165-5175.
WU Chunling, HU Wenbo, MENG Jinghao, et al. State of charge estimation of lithium-ion batteries based on maximum correlation-entropy criterion extended Kalman filtering algorithm[J]. *Transactions of China Electrotechnical Society*,2021, 36 (24): 5165-5175.
- [12] 耿攀,许梦华,薛士龙. 基于LSTM循环神经网络的电池SOC预测方法[J]. *上海海事大学学报*,2019,40(3):120-126.
GENG Pan, XU Menghua, XUE Shilong. Battery SOC estimation method based on LSTM recurrent neural network[J]. *Journal of Shanghai Maritime University*, 2019,40 (3): 120-126.
- [13] LI N, ZHANG Y, HE F, et al. Review of lithium-ion battery state of charge estimation[J]. *Global Energy Interconnection*, 2021,4(6):619-630.
- [14] 刘志聪,张彦会. 锂离子电池参数辨识及荷电状态的估算[J]. *储能科学与技术*,2022,11(11):3613-3622.
LIU Zhichong, ZHANG Yanhui. Parameter identification and state of charge estimation of lithium-ion batteries[J]. *Energy Storage Science and Technology*, 2022,11(11):3613-3622.
- [15] SUN C, LIN H, CAI H, et al. Improved parameter identification and state-of-charge estimation for lithium-ion battery with fixed memory recursive least squares and sigma-point Kalman filter[J]. *Electrochimica Acta*, 2021,387:138501.
- [16] 胡文. 基于温度影响的锂离子电池建模及EKF算法下的荷电状态估算研究[D]. 徐州:中国矿业大学,2020.
HU Wen. Study on modeling of lithium-ion battery based on temperature effect and SOC estimation based on EKF algorithm[D]. Xuzhou: China University of Mining and Technology, 2020.
- [17] YANG F, XING Y, WANG D, et al. A comparative study of three model-based algorithms for estimating state-of-charge of lithium-ion batteries under a new combined dynamic loading profile[J]. *Applied Energy* 2016; 164: 387-399.
- [18] CHAOUI H, IBE-EKEOCHA C C. State of charge and state of health estimation for lithium batteries using recurrent neural net-works[J]. *IEEE Transactions on Vehicular Technology*, 2017,66(10):8773-8783.
- [19] 潘锦业,王苗苗,阚威,等. 基于Adam优化算法和长短期记忆神经网络的锂离子电池荷电状态估计方法[J]. *电气技术*,2022,23(4):25-30+36.
PAN Jingye, WANG Miaomiao, KAN Wei, et al. State of charge estimation of lithium-ion battery based on Adam optimization algorithm and long short-term memory neural network[J]. *Electrical Engineering*,2022,23(4):25-30+36.
- [20] 杜生鑫,金阳. 锂离子电池储能舱风冷散热数值模拟与优化[J]. *电力工程技术*,2022,41(6):58-64.
DU Shengxin, JIN Yang. Numerical simulation and optimization of air cooling heat dissipation of lithium-ion battery storage cabin[J]. *Electric Power Engineering Technology*, 2022,41(6): 58-64.
- [21] CHUNG D W, KO J H, YOON K Y. State of charge estimation of lithium ion batteries using LSTM deep learning method[J]. *Journal of Electrical Engineering & Technology*,2022,17(3):1931-1945.
- [22] 朱文凯,周星,刘亚杰,等. 基于递推门控循环单元神经网络的锂离子电池荷电状态实时估计方法[J]. *储能科学与技术*,2023,12(2):570-578.
ZHU Wenkai, ZHOU Xing, LIU Yajie, et al. Real time state of charge estimation method of lithium-ion battery based on recursive gated recurrent unit neural network[J]. *Energy Storage Science and Technology*,2023,12(2):570-578.
- [23] YANG F, ZHANG S, LI W, et al. State-of-charge estimation of lithium-ion batteries using LSTM and UKF [J]. *Energy*,2020,201:20201808608572.
- [24] 舒征宇,翟二杰,李镇翰,等. 基于Dropout优化算法和LSTM的铅酸蓄电池容量预测[J]. *电源学报*,2023,21(5):173-181.
SHU Zhengyu, ZHAI Erjie, LI Zhenhan, et al. Prediction of lead-acid battery capacity based on dropout optimization algorithm and LSTM[J]. *Journal of Power Supply*, 2023,21(5):173-181.
- [25] 欧旭鹏,唐云,张凯,等. 基于CEEMDAN-IDOA-BiLSTM的超短期风电功率预测[J]. *电网与清洁能源*, 2023,39(11):142-150.
OU Xupeng, TANG Yun, ZHANG Kai, et al. The ultra short term wind power prediction based on CEEMDAN-IDOA-BiLSTM[J]. *Power System and Clean Energy*, 2023, 39(11): 142-150.
- [26] CHEMALI E, KOLLMEYER P J, PREINDL M, et al. Long short-term memory-networks for accurate state of charge estimation of Li-ion batteries[J]. *IEEE Transactions on Industrial Electronics*,2018,65(8):6730-6739.