

基于深度学习的锂电池SOC和SOH联合估计研究

郭建康, 王子赞*

江南大学物联网技术应用教育部工程研究中心, 江苏 无锡

收稿日期: 2023年3月6日; 录用日期: 2023年4月4日; 发布日期: 2023年4月12日

摘要

目前, 新能源的开发和利用越来越受到世界各国的关注, 锂离子电池以其优良的特性逐渐成为世界上应用最为广泛的储能元件。因此, 保障锂离子电池的安全可靠运行也成为当下的研究热点, 然而其荷电状态(SOC)和健康状态(SOH)无法被直接测量。为了实现锂离子电池SOC和SOH的联合估算, 本文分析了SOC和SOH之间的关联, 并设计一种基于深度学习的锂离子电池SOC和SOH联合估算方法。本方法通过采集到的电流、电压、充放电功率、电压变化率等多个参数丰富特征值样本, 利用CNN卷积神经网络估计锂电池的内阻, 用于SOH的估算。其中, 数据为一维数据, 需要对CNN神经网络结构进行调整。进一步将估计得到的SOH与采集到的数据利用GRU-RNN神经网络联合估计得到锂电池SOC。此方法不需搭建电池模型, 甚至不需要设置SOC初值, 也可以快速收敛。

关键词

锂电池, 深度学习, 电池荷电状态, 电池健康状态, 卷积神经网络, 门控循环单元神经网络

A Joint Estimation Study Based on Deep Learning of SOC and SOH for Lithium Batteries

Jiankang Guo, Ziyun Wang*

Engineering Research Center of Internet of Things Technology Applications of Ministry of Education, Jiangnan University, Wuxi Jiangsu

Received: Mar. 6th, 2023; accepted: Apr. 4th, 2023; published: Apr. 12th, 2023

*通讯作者。

文章引用: 郭建康, 王子赞. 基于深度学习的锂电池 SOC 和 SOH 联合估计研究[J]. 计算机科学与应用, 2023, 13(4): 672-679. DOI: 10.12677/csa.2023.134066

Abstract

Nowadays, the development and utilization of new energy have attracted more and more attention in the world. Lithium-ion batteries have gradually become the most widely used energy storage component in the world because of their excellent characteristics. Therefore, ensuring the safe and reliable operation of lithium-ion batteries has become a current research focus, but their State of Charge (SOC) and State of Health (SOH) cannot be directly measured. In order to realize the joint estimation of SOC and SOH for lithium-ion batteries, this paper analyzes the correlation between SOC and SOH, and designs a joint estimation method based on deep learning of SOC and SOH for lithium-ion batteries. This method uses CNN convolution neural network to estimate the internal resistance of lithium batteries, which is used for the estimation of SOH, through collecting multiple parameters such as current, voltage, charge-discharge power, voltage change rate and other rich eigenvalue samples. The data is one-dimensional data, and the structure of CNN neural network needs to be adjusted. Further, the estimated SOH and the collected data are combined to estimate the lithium batteries' SOC using GRU-RNN neural network. This method does not need to build a battery model, and even can quickly converge without setting the initial value of SOC.

Keywords

Lithium Batteries, Deep Learning, State of Charge (SOC), State of Health (SOH), Convolutional Neural Network, Recurrent Neural Network with Gated Recurrent Unit

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着锂离子电池技术的发展,其逐渐作为常用的储能元件被引入电动汽车、便携式电子设备以及各类具有储能需求的装置中[1],以实现电能的存储和转化。对于锂离子电池而言,SOC和SOH是最关键的状态量。其中,SOC被定义为剩余容量与最大可用容量之比[2],其能够量化当前电池内部所剩能量,准确的SOC估算能够提高锂离子电池容量和能量利用率,有利于电池管理系统保证锂离子电池工作在安全运行区间,以延长锂离子电池使用寿命;SOH则尚没有统一的定义,通常以锂离子电池容量和内阻的变化来定义[3][4],其能够定量描述锂离子电池老化情况,准确的SOH估算直接影响锂离子电池性能发挥,并为老化锂离子电池的更换提供重要参考依据,对于锂离子电池最佳性能的发挥和安全运行具有重大意义。

SOC和SOH估算方法可以分为基于模型的联合估算方法和数据驱动的估算方法。其中,传统SOC估计方法包括安时积分法、开路电压法、放电测试法和内阻测试法。常见的基于电池等效模型的估算方法为KF算法、PF算法和观测器法等。观测器法在电池SOC的精度估算以及鲁棒性上表现较好,但其性能容易受噪声影响,因此未被广泛使用。数据驱动方法具备自主学习能力,在大量的数据进行训练下,能够基于自身反馈调节,优化参数,以获得更好的估计结果。通常数据驱动有神经网络法、支持向量机、模糊逻辑法等[5]。

传统的SOH估计方法主要为直接测量法和最小二乘法,直接测量法一般通过测量内阻或者容量来估计电池SOH。最小二乘法用于电池模型参数的辨识,结合等效电路模型,拟合电池内部参数和电池老化

之间的函数关系, 对当前的电池 SOH 做出估计。基于滤波的算法通常是利用自适应滤波算法实时更新电池内部状态来获取电池等效内阻参数。数据驱动方法在不考虑锂离子电池老化机理和内部电化学反应的情况下, 试图从电池表征数据中提取出电池退化的可用特征, 然后通过机器学习方法建立这些特征与 SOH 之间的关系[6]。

虽然现有的研究已经取得了较好的实验结果, 但仍有一些需要改进的地方。对于锂电池的 SOC 估计, 大多数文献没有考虑电池老化对 SOC 估计的影响。事实上, 随着电池的老化, 电池的容量会逐渐降低, 外部可测参数的特性可能会发生变化, 这将对 SOC 的估计提出很大的挑战[7]。SOC 和 SOH 的联合估算方法是在考虑 SOC 和 SOH 耦合关系的基础上, 利用估算出的 SOH 来更新迭代 SOC, 以实现 SOC 的更新。由于对 SOC 估算时考虑了 SOH 的影响, 联合估算方法能够跟随锂离子电池当前状态变化进行调整, 更加准确地实现 SOC 和 SOH 同时估算。

基于模型的联合估算方法需要依赖锂离子电池电化模型或者等效电路模型, 使用双观测器相互迭代分别实现 SOC 和 SOH 估算。虽然基于模型的 SOC 和 SOH 联合估算方法能够通过性能强大的各种改进观测器实现了理想的效果, 但电池模型的不准确一直是限制该方法的主要难题, 即不准确的电池模型直接影响 SOC 和 SOH 估算精度, 而且随着电池工况的变化及老化过程的发生, 电池模型中的参数不确定性将进一步增大, 从而进一步影响估算准确性。然而, 数据驱动的联合估算模型能够回避电池模型, 转而通过机器学习的方式获取 SOC 和 SOH 变化特性, 不需要依赖锂离子电池模型, 且不需对 SOC 和 SOH 进行解耦并分别进行估算。

至于常用于电池 SOC 估算的神经网络则是 LSTM 神经网络。目前, 已经有大量的文献证明了 LSTM 神经网络在电池 SOC 估算领域的优秀表现。近年来, 随着深度学习的不断发展, 出现了越来越高效的神经网络, 如卷积网络、门控循环单元、双向长短期记忆(BiLSTM)等。这些神经网络在锂离子电池 SOH 领域的应用还有待进一步发展。

2. 锂离子电池 SOC 和 SOH 关联性分析

锂离子电池 SOC 和 SOH 均为表示锂离子电池状态的定义量, 而不是具体物理量。其中, 常见的对锂离子电池 SOC 的定义有两种[8], 第一种指在特定放电倍率条件下, 电池剩余电量占相同条件下额定容量的百分比, 其中 Q_t 是为电池剩余的电量, Q_i 为以电流 I 放电时所具有的容量。

$$\text{SOC} = \frac{Q_t}{Q_i} \quad (1)$$

第二种方法则是通过放出电量 Q 求得当前的荷电状态:

$$\text{SOC} = 1 - \frac{Q}{Q_i} \quad (2)$$

两种定义方式下, 电池完全充电时, $\text{SOC} = 100\%$, 电池完全放电时, $\text{SOC} = 0$ 。式中观察可以发现, 因为 Q_i 在不同倍率放电下所测得的电池实际容量会有所不同, 一般用电池标称容量 Q_N 来代替不同放电倍率下的额定容量 Q_i 。

通常情况下, SOH 被定义为当前时刻与初始状态下性能参数的比值, 可以从容量和内阻两个角度进行定义[9], 取值范围为 0~100%。容量角度定义方法如下式(3):

$$\text{SOH} = \frac{Q_t}{Q_{norm}} \quad (3)$$

其中, Q_t 为当前时刻电池实际容量, Q_{norm} 为出厂时额定容量, 两者均为电池在标准放电条件下 SOC

从 100% 到 0 过程中电池实际放出的电荷量。由于锂电池在使用过程中内阻会发生变化, 并且与 SOH 存在一定的对应关系, 因此也可以从内阻角度定义, 表达式(4)如下:

$$SOH = \frac{R_{eol} - R_{now}}{R_{eol} - R_{new}} \quad (4)$$

其中, R_{now} 为当前时刻内阻, R_{new} 为电池出厂时的内阻, R_{eol} 为电池达到报废标准时的内阻。从容量的角度定义锂离子电池 SOC 时需要将 SOH 考虑进去[10], 锂离子电池当前最大可用容量与标称容量之比, 由以上分析可以推导出:

$$SOC = \frac{Q_{store}}{C_0 \cdot SOH} \quad (5)$$

式中: Q_{store} 为锂离子电池当前状态所存储的电量; C_0 为锂离子电池标称容量。由式(5)可以看出, 从机理分析角度而言, 锂离子电池 SOC 和 SOH 之间存在关联, 且 SOH 对 SOC 的影响随着 SOH 的变化而变化。并且随着锂离子充放电周期的增加, 其内阻总体是在变大的。在常温下的一次充放电时, 其变化浮动不大, 且内阻会在放电时变现为轻微上升, 充电时表现为轻微下降。

3. 基于深度学习的锂离子电池 SOC 和 SOH 联合估计框架搭建

在基于状态空间模型的 SOC 估计中, SOC 与电压和电流等参数的关系具有很强的非线性映射关系, 且由于系统中的参数会随着电池充放电次数增加而改变。利用数据驱动法进行 SOC 估计, 不需要对电池内部复杂的工作机理进行了解, 而是把电池这个复杂的非线性系统看做一个黑箱模型, 只需要采集电池特性数据(电压、电流等)进行网络模型训练, 可很好地模拟出电池的特性, 训练数据越丰富, 训练出的模型就越接近于真实电池特性。因此, 我们可以利用已经采集并计算出的电池内阻进行 SOH 计算, 并将预测到的 SOH 加入 SOC 训练模型中, 增加数据丰富度。

本文将卷积神经网络(CNN)与门控循环单元循环神经网络(GRU-RNN)进行结合, 从而实现基于深度学习的锂离子电池 SOC 和 SOH 状态的联合估计, 其联合估计模型框架如图 1 所示。

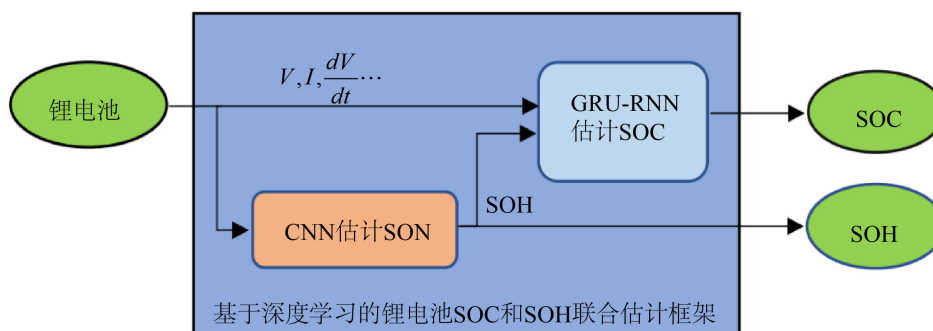


Figure 1. Joint estimation framework of SOC and SOH state of lithium-ion batteries based on deep learning

图 1. 基于深度学习的锂离子电池 SOC 和 SOH 状态的联合估计框架

其中, GRU-RNN 是为了解决简循环神经网络的长期依赖性的问题而提出的一种循环神经网络, 其相对于长短期记忆循环神经网络(LSTM-RNN)而言, 能够同时降低对计算复杂度和存储空间的需求并能提高收敛速度。由于锂离子电池是一个具有长时依赖性响应的动态系统, 其当前 SOC 与历史 SOC、电压、电流等参数均存在联系。因此, 将 GRU-RNN 用于 SOC 估计能够更好地处理时间序列问题。其整体结构

如图 2 所示。

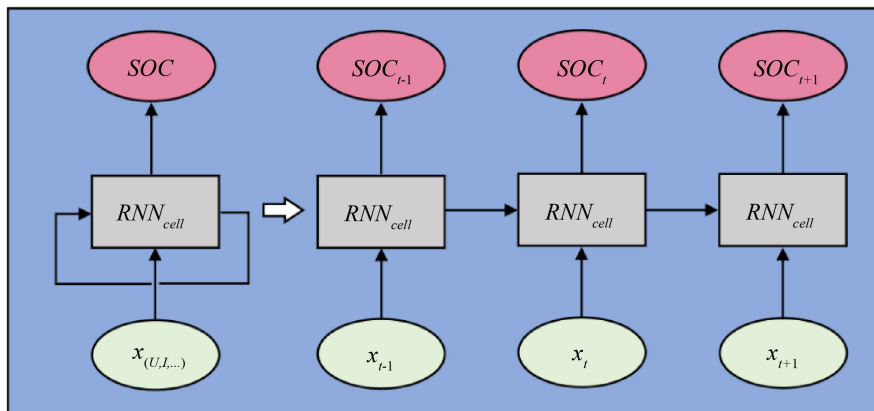


Figure 2. SOE state estimation based on GRU-RNN framework
图 2. 基于 GRU-RNN 框架的 SOE 状态估计

在 GRU-RNN 架构的基础上, 增加处理数据空间关联性更强的 CNN 架构, 以算法本身的数据分析能力和非线性映射能力, 来适应电池在实际使用过程中复杂多变的影响因素。其中, CNN 由单个输入层(input layer)、多个卷积层(convolutional layer)、多个池化层(pooling layer)、多个全连接层(dense layer)、单个输出层(output layer)构成。整体结构如图 3 所示。

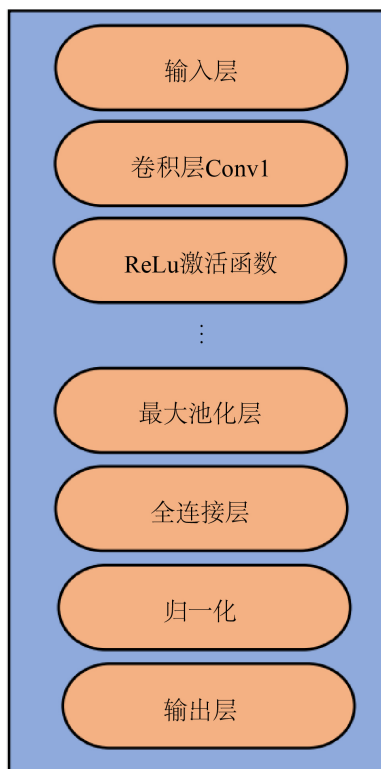


Figure 3. SOH state estimation based on CNN framework
图 3. 基于 CNN 框架的 SOH 状态估计

4. 深度学习模型搭建

本实验基于 CPU (Intel Core i7-9750h 2.60 GHz)、GPU(NVIDIA GeForce GTX 1650 4 GB)、RAM 内存 (16 GB)、Windows 操作系统。

4.1. CNN 网络模型设计

本文搭建的 CNN 神经网络用于预测锂电池 SOH, 其结构由一个输入层, 五个卷积层, 五个批标准化层, 五个激活函数层、三个最大池化层、一个全连接层和一个输出层所构成, 共有 21 层。其具体流程如下:

1) 数据预处理: 选取电压 V 、电流 I 、充电能量 Wh_1 、放电能量 Wh_2 、电压变化率 dv/dt 五个参数作为输入数据, 输出为 SOC 参考值, 分别做归一化处理。接着, 将归一化后的输入数据分别排列成 $W \times H$ 的网格, 叠加成深度为 5 的输入数据, 网络最终的输出值还需要反归一化, 得到 SOC 的估计值。

2) 卷积层选择: 卷积层选择一维卷积, 卷积块内卷积核大小为 3×1 , 第一层设置 16 个滤波器, 第二层设置 32 个滤波器, 第三层设置 64 个滤波器, 第四层设置 128 个滤波器, 第五层设置为 256 个滤波器。指定移动步长为 1, padding 填充为 0。

3) 批标准化: 更深的神经网络拥有更强大的非线性映射能力, 但也会产生较深层网络学习效率低、收敛速度慢等问题。即使我们对输入数据进行了归一化处理, 训练过程中每层网络输入的分布也可能会发生偏移。因此, 我们在每个卷积层与激活函数之间添加批标准化层(batch normalization), 使得每一层网络的输入在训练过程中均保持较为均匀的分布, 从而使网络传播更加有效。

4) 激活函数: 选用线性整流函数 ReLU, 如公式(6)所示:

$$\text{ReLU} = \max(\omega x + b, 0) \quad (6)$$

5) 最大池化层: 最大池化层的作用主要为提取特征值, 降低了上层的计算复杂度。模型中共设置 3 个 Max pooling 池化层滤波器, 每个 Max pooling 池化层滤波器的作用范围为 3×1 , 且将该范围内最大的值作为主要信息保留并输出。

6) 损失函数: 选用回归类问题较为常用的均方根误差(RMSE)损失函数, 可以有效衡量观测值与真实值之间的偏差。

模型中采用 Adam 自适应优化器最小化目标函数, 优化器学习率为 0.001, 步长和迭代次数设置为 24 和 2000。

4.2. GRU-RNN 网络模型设计

SOC 估算模型中的 GRU-RNN 由一个输入层、一个隐藏层、一个全连接层和一个输出层组成, 且输入层、隐藏层、全连接层和输出层的节点分别设置为 3、100、100 和 1, 激活函数为 tanh, 加入 dropout 层防止过拟合, 在每次训练的时候, 每个神经元有 10% 的几率被移除。将均方根误差(RMSE)损失函数作为目标函数, 并采用 Adam 自适应优化器, 最小化目标函数, 优化器学习率为 0.0001 步长和迭代次数分别设置为 10 和 100。

5. SOC 估计结果预测

利用深度学习方法对锂离子电池从初始状态 SOC = 60% 充至 SOC = 100%, 进行了一次深度充放电周期, 此时 SOC 和 SOH 状态的联合估计结果如图 4、图 5 所示。




Figure 4. Internal resistance state estimation of lithium batteries during primary charge and discharge period

图 4. 锂电池一次充放电周期电池内阻状态估计




Figure 5. SOC state estimation of lithium batteries during primary charge and discharge period

图 5. 锂电池一次充放电周期电池 SOC 状态估计

由图 4 可以看出, 本次实验中对利用 CNN 卷积神经网络对电池内阻估计效果较为理想, 平均误差不超过 0.001。图 5 所示, 利用 GRU-RNN 网络对 SOC 预测结果中 SOC 总体偏差不超过 2%, SOC 的预测过程中 RMSE 的值为 0.020482。图 6 为剔除噪声数据后的 SOC 估算过程的平均绝对误差, 误差值不超过 1.6%。

综上所述, 本文所提出的基于深度学习的锂离子电池 SOC 和 SOH 联合估算模型得到了有效性的验证, 其不仅能够实现锂离子电池 SOC 和 SOH 的同时估算, 还因考虑到锂离子电池老化因素影响, 从而提高了锂离子电池 SOC 估算精度。




Figure 6. Average absolute error of SOC estimation process

图 6. SOC 估算过程的平均绝对误差

6. 结论

深度学习方法提取的特征层级更深, 适应性更强, 利用其不同的网络特性对特征进行自适应学习, 可以使特征提取更加全面, 避免了传统算法中建立电池等效模型和手动提取输入特征等复杂的环节。

通过深度学习的方法联合 SOH 对 SOC 进行估计, 在短时间内的充放电实验中, 电池的 SOH 并不会发生显著变化, 而 SOC 显示出明显的时间序列特性, SOH 估计结果能够修正锂离子电池老化状态下的 SOC 估算结果, 从而能够提高长期估计 SOC 的精度。

参考文献

- [1] 刘昊天. 基于深度学习的锂离子电池 SOC 及 SOH 估算方法研究[D]: [硕士学位论文]. 天津: 天津大学, 2020.
- [2] Li, C.R., Xiao, F. and Fan, Y.X. (2019) An Approach to State of Charge Estimation of Lithium-Ion Batteries Based on Recurrent Neural Networks with Gated Recurrent Unit. *Energies*, **12**, Article 1592. <https://doi.org/10.3390/en12091592>
- [3] Dai, H.D., Zhao, G.C., Lin, M.Q., Wu, J. and Zheng, G.F. (2019) A Novel Estimation Method for the State of Health of Lithium-Ion Battery Using Prior Knowledge-Based Neural Network and Markov Chain. *IEEE Transactions on Industrial Electronics*, **66**, 7706-7716. <https://doi.org/10.1109/TIE.2018.2880703>
- [4] Wang, Z.K., Zeng, S.K., Guo, J.B. and Qin, T.C. (2019) State of Health Estimation of Lithium-Ion Batteries Based on the Constant Voltage Charging Curve. *Energy*, **167**, 661-669. <https://doi.org/10.1016/j.energy.2018.11.008>
- [5] 王道剑. 锂离子电池 SOC 和 SOH 联合估算算法研究[D]: [硕士学位论文]. 长春: 吉林大学, 2022.
- [6] Fan, Y.X., Xiao, F., Li, C.R., Yang, G.R. and Tang, X. (2020) A Novel Deep Learning Framework for State of Health Estimation of Lithium-Ion Battery. *Journal of Energy Storage*, **32**, Article ID: 101741. <https://doi.org/10.1016/j.est.2020.101741>
- [7] Gong, Q.R., Wang, P. and Cheng, Z. (2022) A Data-Driven Model Framework Based on Deep Learning for Estimating the States of Lithium-Ion Batteries. *Journal of the Electrochemical Society*, **169**, Article ID: 030532. <https://doi.org/10.1149/1945-7111/ac5bac>
- [8] 麻友良, 陈全世, 齐占宁. 电动汽车用电池 SOC 定义与检测方法[J]. 清华大学学报(自然科学版), 2001, 41(11): 95-97+105.
- [9] 朱丽群, 张建秋. 一种联合锂电池健康和荷电状态的新模型[J]. 中国电机工程学报, 2018, 38(12): 3613-3620.
- [10] Rivera-Barrera, J.P., Muñoz-Galeano, N. and Sarmiento-Maldonado, H.O. (2017) SoC Estimation for Lithium-Ion Batteries: Review and Future Challenges. *Electronics*, **6**, Article 102. <https://doi.org/10.3390/electronics6040102>