

# 基于 LSTM 神经网络的动力电池 SOC 估算研究

郑永飞<sup>1</sup> 文怀兴<sup>1\*</sup> 韩昉<sup>1</sup> 杨鑫<sup>2</sup> 张晶<sup>3</sup>

<sup>1</sup>(陕西科技大学机电工程学院 陕西 西安 710021)

<sup>2</sup>(西安冠通数源电子有限公司 陕西 西安 710065)

<sup>3</sup>(西安应用光学研究所 陕西 西安 710065)

**摘要** 电池监控是电动汽车安全行驶的必要手段,电池的荷电状态(State of Charge, SOC)则是衡量电动汽车安全性能的直接指标。针对锂离子电池的非线性特性,设计一种基于深度学习的长短期记忆网络(Long Short-Term Memory, LSTM)SOC 预测模型。通过 MATLAB 实验验证以及与其他算法的比较分析得出,该模型可以有效解决传统神经网络容易陷入局部最小值以及出现梯度消失、爆炸等问题,估算误差小于 2%,具有较高的精度和应用前景。

**关键词** 动力电池 LSTM 荷电状态 MATLAB

中图分类号 TP3 TM912.9 文献标志码 A DOI:10.3969/j.issn.1000-386x.2020.03.014

## SOC ESTIMATION OF POWER BATTERY BASED ON LSTM NEURAL NETWORK

Zheng Yongfei<sup>1</sup> Wen Huaixing<sup>1\*</sup> Han Fang<sup>1</sup> Yang Xin<sup>2</sup> Zhang Jing<sup>3</sup>

<sup>1</sup>(College of Mechanical and Electrical Engineering, Shaanxi University of Science and Technology, Xi'an 710021, Shaanxi, China)

<sup>2</sup>(Xi'an GuanTong Digital Source Electronics Co., Ltd, Xi'an 710065, Shaanxi, China)

<sup>3</sup>(Xi'an Institute of Applied Optics, Xi'an 710065, Shaanxi, China)

**Abstract** Battery monitoring is a necessary means for safe driving of electric vehicles. State of Charge (SOC) of batteries is a direct indicator to measure the safety performance of electric vehicles. In view of the nonlinear characteristics of lithium-ion batteries, this paper designs a long short-term memory (LSTM) SOC prediction model based on deep learning. Through the experimental verification of MATLAB and comparative analysis with other algorithms, it is concluded that this model can effectively solve the problems of traditional neural network, such as easily falling into local minimum value, gradient disappearance, explosion and so on. The estimation error is less than 2%, and it has high accuracy and application prospect.

**Keywords** Power battery LSTM State of charge MATLAB

## 0 引言

动力电池作为电动汽车的关键部件,承担着车辆运行过程中能量存储和释放的重任。荷电状态 SOC 是车载电池管理系统中的一个重要监测参数,对其精确估算可避免电池产生过充过放现象,提高电池的使用寿命和效率<sup>[1]</sup>,同时也可以给整车控制器提供参考,以便合理分配能量<sup>[2]</sup>。SOC 数值无法通过直接测量

的方法获得<sup>[3]</sup>,只能间接通过对电池的特征参数进行分析处理来获得,但电池在使用过程中的温度、电压、电流、内阻等特征参数具有高度的非线性特性,使得准确估算 SOC 具有较大的难度。

现阶段成熟使用的方法主要是通过检测电池特征参数如电压、电流、内阻、充放电倍率等<sup>[4-8]</sup>,并以此建立模型进行 SOC 估算,估算精度的高低在很大程度上取决于建立的模型精度,并且使用传统的数学方法建立电池模型非常困难,可靠性较低<sup>[9]</sup>。

神经网络能够逼近任何非线性,具有强大的处理非线性的能力,能够快速、高精度地估算电池 SOC<sup>[10]</sup>。但传统的 BP 算法容易陷入局部最小点而不是全局最小点<sup>[11]</sup>,且在实际使用中容易产生梯度消失和爆炸等问题,同时不能够很好地利用电池特征参数在时间序列上变化前后之间的关系,存在一定的局限性。LSTM 是一种递归神经网络,属于深度学习范畴,对于处理时间序列数据具有强大的建模和分析能力,可用来处理与时间序列高度相关的问题<sup>[12]</sup>。

针对动力电池 SOC 的长期依赖及时间序列的特性,本文设计了一种基于 LSTM 神经网络的预测模型,并在 MATLAB 中搭建 LSTM 网络进行仿真验证。该方法能够有效解决传统神经网络容易陷入局部最小值以及梯度消失、爆炸等问题,并与 BP、PSO-BP 等现有算法进行了比较分析,验证了本方法的适用性和估算精度。

## 1 神经网络

### 1.1 循环神经网络 RNN

BP 神经网络具有较强的学习能力和非线性逼近能力,但也存在缺陷,如在训练过程中容易产生过拟合以及陷入局部最小值等现象。此外,使用前馈神经网络进行预测时,没有对历史信息进行记忆和使用,未能解决时间序列数据所具有的长期依赖特性以及上下文相关联的问题。

随着神经网络不断发展,形成了循环神经网络(Recurrent Neural Network, RNN)。RNN 内部含有循环结构,这种结构使得上一时刻隐藏层的状态数据和当前时刻输入的数据共同形成新的输入数据,结构原理如图 1 所示。RNN 可以保存历史信息并将其运用到当前的预测任务上,并随着新数据的输入而一直更新,能较好地解决时间序列的长期依赖问题。然而 RNN 在实际使用中,梯度爆炸或消失现象时有发生,从而影响了 RNN 预测的精度。




图1 RNN 结构原理图

### 1.2 LSTM 神经网络

为了解决上述 RNN 的问题,在 RNN 神经网络的隐藏层引入 LSTM 细胞结构单元取代原来的隐藏层单元,形成 LSTM 神经网络模型,结构如图 2 所示。细胞状态贯穿于整个网络,是 LSTM 的核心,在工作过程中只需进行少量的线性计算,就可以在长期的传播过程中使梯度信息保持稳定。




图2 LSTM 神经网络结构原理图

LSTM 网络具有三种门结构,分别是输入门、遗忘门和输出门,这些门通常由一个 Sigmoid 神经网络层和逐点乘积操作组成,用来处理细胞状态中的信息。其中删除不需要的历史信息由遗忘门完成,当前输入数据对记忆单元状态的影响由输入门决定,输出信息由输出门决定。当打开门时(Sigmoid 输出为 1 时),可以通过一切信息;当关上门时(Sigmoid 输出为 0),拒绝一切信息通过。LSTM 通过增加以上三种门限,使得自循环的权重始终处于动态变化,可保证模型参数在不变的条件下,不同时刻的积分尺度发生动态改变,从而解决 RNN 存在的梯度问题。

以下公式中,  $\tanh$ 、 $\sigma$  表示激活函数,  $t$  时刻对应的输入门、遗忘门、输出门三种门结构和细胞状态分别由  $i_t$ 、 $f_t$ 、 $o_t$  和  $c_t$  表示,对应的权值矩阵分别由  $W_i$ 、 $W_f$ 、 $W_o$  和  $W_c$  表示,各门状态的偏置分别由  $b_i$ 、 $b_f$ 、 $b_o$  和  $b_c$  表示。

(1) 由遗忘门的 Sigmoid 层决定,对细胞状态中的部分信息进行遗忘。以上一层的输出数据  $h_{t-1}$  和此刻的输入数据  $x_t$  作为新的输入,得到细胞状态在  $t-1$  时刻的输出:

$$i_t = \sigma(W_i h_{t-1} + W_i x_t + b_i) \quad (1)$$

(2) 将信息存储在细胞状态中,主要由以下步骤完成:首先把输入门中 Sigmoid 层的结果  $i_t$  作为将更新的信息;接着由  $\tanh$  层创建新向量  $c_t$  并增加到细胞状态中;最后将  $f_t$  与旧的细胞状态  $c_{t-1}$  相乘完成信息遗忘功能,并加上候选信息  $i_t c_t$  的值,使细胞状态更新。

$$f_t = \sigma(W_f h_{t-1} + W_f x_t + b_f) \quad (2)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_c h_{t-1} + W_c x_t + b_c) \quad (3)$$

(3) 使用 Sigmoid 层对细胞状态进行处理,选择要输出的部分信息,再用 tanh 进行处理,将得到的两部分信息相乘便可得到输出值。

$$o_t = \sigma(W_o h_{t-1} + W_o x_t + b_o) \quad (4)$$

由上可得  $t$  时刻 LSTM 的输出信号为:

$$h_t = o_t \tanh(c_t) \quad (5)$$

## 2 基于 LSTM 的 SOC 预测模型

### 2.1 特征选取

电动汽车在实际的行驶过程中会面临各种不同的工况,同时还存在着各种不确定因素,因此在搭建预测模型前训练特征的提取非常关键,在能够较好地反映动力电池实际工作状态的同时数据还要易于获得。电池内部各种参数如内阻、电解溶液浓度变化等的测量往往需要建立精确的模型或者使用大型仪器才能测得,且需要在静态时才可以获得,不适用于实际工作条件。而电池在工作过程中的电压、电流、温度等参数,借助于电池管理系统,可以获得较为精确的数值,且这些参数可直接体现电池的工作状态,在 SOC 估算中能够起到重要作用,因此本文选择电压、电流、温度作为模型的输入特征,以增强算法的适用性和实用性。

### 2.2 模型建立

本文建立的基于 LSTM 动力电池 SOC 预测模型主要由输入层、隐藏层和输出层组成,基本结构如图 3 所示,其中  $X$  表示输入特征, $Y$  表示输出特征。




图 3 基于 LSTM 的动力电池 SOC 预测模型

输入层主要实现数据预处理、数据集划分等;在输出层中,使用训练好的 LSTM 模型计算预测获得的输出数据,并对预测得到的数据进行反标准化等处理。在时间维度方向上,LSTM 模型所包含的隐藏层展开即可形成深度学习网络,自动挖掘 SOC 的数值变化趋势与这些影响因素之间的内在关系,实现动力电池 SOC 的预测。

## 3 实验

### 3.1 充放电实验

选用 32650 磷酸铁锂动力电池进行倍率放电实验,额定容量为 6 Ah,标称电压为 3.2 V,终止充电电压为 3.65 V,终止放电电压为 2.5 V。充电过程中首先使用恒流 0.5 C 开始充电,当电池两端电压达到 3.65 V 时,变为恒压继续充电,电流逐渐变小到 20 mA 时,整个充电过程结束。放电过程分别以 0.2、0.5、1、2、3 C 进行,直到电池电压下降到 2.5 V 时结束放电过程。循环进行以上实验,并定期记录电池的电压、电流、温度、能量、功率等参数,图 4 为不同倍率下的放电容量变化。根据实验获得的数据,选取 2 290 组作为本文的实验数据,其中 1 990 组为训练数据,300 组为测试数据,根据以上数据在 MATLAB 2018a 中搭建模型进行实验验证。




图 4 不同倍率下的放电实验

### 3.2 模型训练与分析

根据建立的 LSTM 模型,在 MATLAB 中进行仿真验证。通过多次实验,本文最终将隐藏层设置为 150 层,每层的隐藏节点设置为 128 个,训练次数设置为 2 500 次,学习率设置为 0.01,将 dropout 设置为 0.5 用来抑制过拟合,优化方法采用 Adam,参数设置完成后,进行模型训练。训练结束后,利用训练好的 LSTM 深度神经网络模型,输入测试样本进行 SOC 预测。

### 3.3 实验结果与误差分析

在 MATLAB 中编写程序进行实验验证。将预测得到的 SOC 曲线和对应的参考值曲线进行比较,并作出误差曲线图,分析 LSTM 神经网络的预测精度和收敛情况,实验结果如图 5、图 6 所示。由图 5 可见,本文设计的 LSTM 神经网络模型表现出了较好的预测性能

以及适用性,能够很好地预测 SOC 的变化趋势。




图 5 LSTM 模型预测结果比较

由图 6 可知,LSTM 模型预测误差整体保持在 2% 以内,且误差变化主要集中在 1.5% 以内,表现出了较高的预测精度,可以很好地满足 SOC 的估算要求。




图 6 误差变化曲线

### 3.4 算法比较分析

为了进一步体现本文方法的优越性能,在 MATLAB 中分别搭建 BP、PSO-BP 算法模型,将各种算法的预测结果与误差进行比较分析,选择均方根误差 (RMSE)、平均绝对误差 (MAE) 和平均绝对百分比误差 (MAPE) 作为模型精度度量标准。计算公式如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}} \quad (6)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |X_i - Y_i| \quad (7)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{X_i - Y_i}{X_i} \right| \quad (8)$$

式中: $X_i$  和  $Y_i$  分别表示  $t$  时刻电池 SOC 的观测值和模型预测的输出值; $N$  为预测样本数。RMSE、MAE、MAPE 值越小则表示模型精度越高,适用性越好。

预测结果如图 7、图 8 和表 1 所示。由图 7、图 8

可知,本文设计的 LSTM 预测模型明显较其他几种算法性能更加优越,预测效果更好,精度更高。从表 1 可以看出,本文方法误差更小,性能更优。




图 7 不同算法的 SOC 预测结果比较




图 8 不同算法的 SOC 预测误差比较

表 1 不同算法的预测性能比较

预测算法	RSME	MAE	MAPE
LSTM	0.008 40	0.008 122	0.016 760
PSO-BP	0.037 16	0.036 309	0.079 465
BP	0.040 00	0.039 293	0.084 094

## 4 结 语

本文将深度学习应用于 SOC 的估算中,针对传统的神经网络算法无法较好利用历史信息,难以实现信息的长期记忆传输等问题,利用深度神经网络 LSTM 优越的时间序列数据处理能力,提出了一种动力电池 SOC 预测方法。将易于获得参考值的电池外特征参数如电压、电流等作为训练输入,降低了预测过程中电池参数的获取难度,增强了实际可操作性。由实验验证以及与其他算法的比较可知,本文设计的 LSTM 预测模型结构简单,性能优越,预测误差保持在 2% 以内,能够较好地完成 SOC 的估算。

- “day-off” adjustment[Z]. 2011.
- [ 3 ] New York ISO. Emergency demand response program manual[Z]. 2013.
- [ 4 ] Kolter J Z, Ferreira J. A large-scale study on predicting and contextualizing building energy usage [C]//Proceedings of the Twenty-Fifth AAAI Conference on Artificial Intelligence, AAAI 2011. AAAI Press, 2011:1349 – 1356.
- [ 5 ] Chan S C, Tsui K M, Wu H C, et al. Load/price forecasting and managing demand response for smart grids: methodologies and challenges[J]. IEEE Signal Processing Magazine, 2012, 29(5):68 – 85.
- [ 6 ] Hagan M T, Behr S M. The Time Series Approach to Short Term Load Forecasting [J]. IEEE Transactions on Power Systems, 1987, 2(3):785 – 791.
- [ 7 ] 杜灵芝,于军琪. GM-WLSSVM 模型在办公建筑电力能耗预测中的应用[J]. 计算机应用与软件, 2018, 35(9):44 – 49,55.
- [ 8 ] Hippert H S, Pedreira C E, Souza R C. Neural networks for short-term load forecasting: a review and evaluation [J]. IEEE Transactions on Power Systems, 2001, 16(1):44 – 55.
- [ 9 ] Ramchurn S D, Vytelingum P, Rogers A, et al. Putting the “smarts” into the smart grid: a grand challenge for artificial intelligence[J]. Communications of the ACM, 2012, 55(4):86 – 97.
- [10] 田英杰,苏运,郭乃网,等. 基于时间序列嵌入的电力负荷预测方法[J]. 计算机应用与软件, 2018, 35(11):55 – 60,73.
- [11] 王瑞,贾瑞玉. 基于形态模式的时间序列相似性度量算法[J]. 计算机应用与软件, 2017, 34(9):253 – 256,305.
- [12] Martinez Alvarez F, Troncoso A, Riquelme J C, et al. Energy time series forecasting based on pattern sequence similarity[J]. IEEE Transactions on Knowledge and Data Engineering, 2011, 23(8):1230 – 1243.
- [13] Shen W, Babushkin V, Aung Z, et al. An ensemble model for day-ahead electricity demand time series forecasting [C]//Proceedings of the fourth international conference on Future energy systems. ACM, 2013:51 – 62.
- [14] 曹梦,刘宝成,何金,等. 基于前趋势相似度的细粒度用户用电负荷预测[J]. 计算机应用与软件, 2018, 35(7):158 – 164,172.
- [15] 刘冬兰,马雷,刘新,等. 基于深度学习的电力大数据融合与异常检测方法[J]. 计算机应用与软件, 2018, 35(4):61 – 64,136.
- [16] Huang Z, Zhu T. Leveraging multi-granularity energy data for accurate energy demand forecast in smart grids [C]//2016 IEEE International Conference on Big Data (Big Data). IEEE, 2016.
- [17] 熊安萍,詹妮,邹毅,等. 大数据环境下一种基于模式匹配的实体统一方法[J]. 计算机应用与软件, 2018, 35(8):87 – 92,97.
- [18] Tofallis C. A better measure of relative prediction accuracy for model selection and model estimation[J]. Journal of the Operational Research Society, 2015, 66(8):1352 – 1362.
- [19] Corbyn J. Time Series Analysis with Applications in R[J]. Journal of the Royal Statistical Society Series A (Statistics in Society), 2011, 174(2):507 – 507.
- [20] 陈焜瑛,张泽星,李文斌. 基于神经网络的股票价格预测模型[J]. 计算机应用与软件, 2014, 31(5):89 – 92.
- [21] 黄岳嵘,徐晓钟,张益铭,等. 基于 ARIMA 和神经网络模型的城市燃气负荷预测[J]. 计算机应用与软件, 2011, 28(12):206 – 209.
- [22] Van Gerven M, Bohte S M. Editorial: artificial neural networks as models of neural information processing[J]. Frontiers in Computational Neuroscience, 2017, 11:114.

~~~~~  
(上接第 81 页)

## 参 考 文 献

- [ 1 ] 廖恩华. 基于神经网络的电动汽车磷酸铁锂电池 SOC 估算方法研究[D]. 成都:电子科技大学. 2011.
- [ 2 ] 张传伟,李林阳,赵东刚. 基于 BP 神经网络法估算动力电池 SOC[J]. 电源技术, 2017, 41(9):1356 – 1357,1368.
- [ 3 ] 刘晓悦,杜晓. 锂离子电池组 SOC 估算方法[J]. 计算机仿真, 2018, 35(10):123 – 126,135.
- [ 4 ] 邓涛,孙欢. 锂离子电池新型 SOC 安时积分实时估算方法[J]. 重庆理工大学学报(自然科学), 2015, 29(1):101 – 106.
- [ 5 ] 潘卫华,刘晓丹. 基于改进卡尔曼滤波的锂电池 SOC 估算研究[J]. 计算机仿真, 2014, 31(3):148 – 150,247.
- [ 6 ] Dang X J, Yan L, Xu K, et al. Open-circuit voltage-based state of charge estimation of lithium-ion battery using dual neural network fusion battery model [J]. Electrochimica Acta, 2016, 188:356 – 366.
- [ 7 ] 孙豪豪,潘庭龙,吴定会. 基于自适应电池模型的 SOC 加权在线估计[J]. 系统仿真学报, 2017, 29(8):1677 – 1684.
- [ 8 ] 鲍慧,于洋. 基于安时积分法的电池 SOC 估算误差校正[J]. 计算机仿真, 2013, 30(11):148 – 151,159.
- [ 9 ] 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(11):95 – 97,105.
- [10] 王通,于洁,马文会,等. 电池管理系统 SOC 估算方法研究进展[J]. 电源技术, 2018, 42(2):312 – 315.
- [11] 权波,杨博辰,胡可奇,等. 基于 LSTM 的船舶航迹预测模型[J]. 计算机科学, 2018, 45(S2):126 – 131.
- [12] 李伟山,王琳,卫晨. LSTM 在煤矿瓦斯预测预警系统中的应用与设计[J]. 西安科技大学学报, 2018, 38(6):1027 – 1035.