

DOI: 10.19783/j.cnki.pspc.200776

# 基于改进 LSTM 的脉冲大倍率工况下锂电池 SOC 估计

明彤彤<sup>1</sup>, 赵晶<sup>2</sup>, 王晓磊<sup>3</sup>, 王凯<sup>1</sup>

(1. 青岛大学电气工程学院, 山东 青岛 266071; 2. 国网山东省电力公司电力科学研究院, 山东 济南 250000;  
3. 青岛海信电子设备股份有限公司, 山东 青岛 266400)

**摘要:** 锂离子电池是电力系统中不可或缺的重要储能元件。针对脉冲大倍率放电下锂离子电池荷电状态(State of Charge, SOC)预测问题, 采用改进的长短期记忆循环神经网络(Long Short-term Memory, LSTM)搭建三元锂电池 SOC 预测模型。所用方法在原有 LSTM 基础上增加两个门控单元, 通过增强 LSTM 内部输入和输出的交互, 提高模型的动态逼近能力。在脉冲大倍率放电工况下, 将所用方法与 BP 神经网络(Back Propagation, BP)、LSTM 神经网络相比较, 验证了算法在脉冲放电下的预测性能。实验结果表明, 改进方法可准确表征三元锂电池工作特性, 满足了 SOC 估计的实际需求。

**关键词:** 三元锂电池; 荷电状态; 脉冲大倍率; 循环神经网络

## SOC estimation of a lithium battery under high pulse rate condition based on improved LSTM

MING Tongtong<sup>1</sup>, ZHAO Jing<sup>2</sup>, WANG Xiaolei<sup>3</sup>, WANG Kai<sup>1</sup>

(1. College of Electrical Engineering, Qingdao University, Qingdao 266071, China; 2. Electric Power Research Institute of State Grid Shandong Electric Power Company, Jinan 250000, China;  
3. Hisense Visual Technology Co., Ltd., Qingdao 266400, China)

**Abstract:** The lithium-ion battery is an indispensable energy storage component in a power system. To predict the State of Charge (SOC) of a lithium-ion battery under high pulse rate conditions, an improved Long Short-Term Memory (LSTM) neural network is used to build the SOC prediction model of a ternary lithium-ion battery. Two gating units are added to the original LSTM to improve the dynamic approximation ability of the model by enhancing the interaction between input and output. Compared with Back Propagation (BP) and LSTM neural networks, the prediction performance of the algorithm under high pulse rate conditions is proved superior. The results show that the improved method can accurately characterize the operating characteristics of ternary lithium batteries, and meet the actual needs of SOC estimation.

This work is supported by the Natural Science Foundation of Shandong Province (No. ZR201910230295) and the Key Project of Natural Science Foundation of Shandong Province (No. ZR202010290147).

**Key words:** ternary lithium battery; state of charge (SOC); high rate pulsed; recurrent neural network

## 0 引言

锂离子电池作为重要的储能元件, 与其他类型电池相比, 具有电压高、比能高、比功率大、工作温度范围广、放电性能好、储存寿命长等优点<sup>[1-2]</sup>, 已被广泛应用于脉冲大倍率放电工况<sup>[3]</sup>。在脉冲大倍率工况下, 锂离子电池状态变化频繁, 电池极化现象较为明显<sup>[4-5]</sup>, 使得电池模型的精确建立变得十

分困难。

作为电池重要的状态之一, 荷电状态(State of Charge, SOC)被定义为剩余容量与最大可用容量的比值, 用来表示所存储的电量。SOC 不仅为电池续航能力提供参考, 而且在电池管理系统(Battery Manage System, BMS)中发挥关键作用, 电池管理系统在工作的过程中需要不断更新电池 SOC 的估计值, 用于计算和修正电池健康状态、能量状态以及功率状态, 并防止电池出现过冲和过放。然而, SOC 不能直接观测, 需要通过电压、电流、温度等可观测变量来间接估计。而如何建立可观测变量与 SOC

**基金项目:** 山东省自然科学基金项目资助(ZR201910230295);  
山东省自然科学基金重点项目资助(ZR202010290147)

之间的非线性映射关系是必须解决的关键问题。

目前对于 SOC 估算的研究多是基于电池的小倍率放电工况, 随着电动汽车的不断发展, 对动力电池的功率性能提出了更高的要求, 在某些特定工况下, 如瞬间加速, 短时间爬坡等需要在短时间内输出大功率的脉冲放电情况下, 给动力电池 SOC 的估计带来了新的挑战<sup>[6-7]</sup>。在这种极端的工况下, 电池内部的化学反应、温度场和内阻都会出现较大的变化, 这些变化会引起电池模型参数的较大波动, 使得电池模型的准确建立变得十分困难。

传统的 SOC 估计方法有开路电压法、安时积分法和电化学阻抗谱法<sup>[8-9]</sup>。开路电压法要求电池长时间保持静止以达到平衡, 从而获得开路电压(OCV)相对于 SOC 曲线, 不适合在线测量<sup>[10]</sup>。安时积分法通过电流积分实现 SOC 预测, 对采样电流精度要求较高。电化学阻抗谱法利用电池阻抗进行 SOC 预测, 在测量的过程中需要电池处于静止状态, 难以现场准确测定<sup>[12]</sup>。以上方法存在各自的局限性, 难以准确表征锂电池在脉冲大倍率放电工况下工作特性, 研究人员投入了大量的时间和精力来提出新的 SOC 估计方法, 包括基于观测器、自适应滤波器和机器学习的方法。

基于观测器的方法(如 Luenberger 观测器<sup>[13-14]</sup>、PI 观测器<sup>[15]</sup>和滑膜观测器<sup>[16-17]</sup>)和自适应滤波器(如卡尔曼滤波器<sup>[18-19]</sup>、递归最小二乘<sup>[20]</sup>和粒子滤波<sup>[21-22]</sup>)利用电池等效模型来估计 SOC 状态, 对电池模型的准确性要求较高, 在脉冲大倍率放电工况下, 电池模型参数的波动较大, 使得电池 SOC 的准确估计变得十分困难。文献[18]利用二次方根容积卡尔曼算法实现 SOC 估计, 针对锂电池在脉冲大倍率放电条件下, 模型参数变化较大的问题, 以电池的二阶 RC 等效电路模型为基础, 通过递推最小二乘法动态识别模型的参数, 但算法复杂度较高。基于机器学习的方法(如支持向量机<sup>[23-24]</sup>和人工神经网络<sup>[25-26]</sup>)试图从统计的角度找出可观测变量(如电流、电压和温度)与电池荷电状态之间的非线性关系。文献[25]提出基于长短期记忆循环神经网络的锂离子电池 SOC 预测方法, 利用循环神经网络的动态逼近和长时记忆能力, 在 6 种脉冲大倍率放电工况下进行放电测试, 实验结果表明, 所用基于循环神经网络的锂电池估计方法可准确表征脉冲大倍率下锂电池工作特性。考虑到锂离子电池是一个具有长时依赖性的动态系统, 本文提出一种基于改进长短期记忆循环神经网络的锂离子电池 SOC 估计方法, 其优势体现如下:

1) 在原有 LSTM 基础上, 通过增加两个门控单

元, 进一步提高模型的动态逼近能力;

2) 所用方法直接基于锂离子电池电流、电压和温度进行预测, 所用参数便于实际测量;

3) 所用方法无需建立电池等效模型, 网络可自行学习输入输出之间的非线性映射关系。

本文第一部分对 LSTM 神经网络及其改进之处进行理论和可行性分析。第二部分介绍了具体试验流程。最后在多种大倍率脉冲工况下, 验证了所提算法在锂电池估计中的有效性。

## 1 神经网络模型

### 1.1 LSTM 循环神经网络

目前主流的深度学习算法包括 BP 神经网络、CNN 卷积神经网络、循环神经网络。虽然以上算法擅长的领域不同, 但训练流程基本一致。

深度学习基本训练流程如图 1 所示: 首先, 将输入  $X$  矩阵送入神经网络, 通过各层神经网络进行数据变换, 得到预测值。其次, 利用损失函数根据预测值  $Y'$  矩阵和真实目标值  $Y$  矩阵得到损失值, 以衡量网络在该输入上的表现。最后, 利用优化器对各层权重进行微调, 以降低当前输入的损失值, 完成误差的反向传播, 实现了模型对非线性映射的学习。

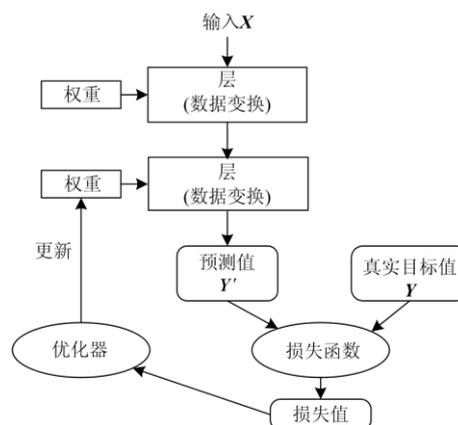


图 1 深度学习基本训练流程

Fig. 1 Basic training process of deep learning

在 BP 神经网络和 CNN 神经网络的训练过程中, 输入  $X$  是单个样本, 在本实验中指的是单一时刻的电压、电流和温度。BP 和 CNN 神经网络在训练的过程中根据单一时刻输入  $X$  来预测 SOC, 并没有考虑 SOC 的长时依赖性。

LSTM 循环神经网络弥补了 BP 和 CNN 在时间序列预测方面的不足。LSTM 神经网络输入  $X$  包括多个样本, 在本实验中输入  $X$  为  $[N, 3]$  的矩阵, 即利用  $N$  个连续时刻的电压、电流和温度来预测电池

SOC。图 2 展示了 LSTM 循环神经网络的内部数据流动， $\mathbf{x}(t)$  矩阵是输入  $\mathbf{X}$  当中单个样本。

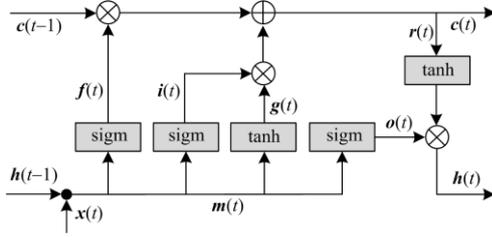


图 2 LSTM 循环神经网络单元

Fig. 2 Long short term memory networks unit

图 2 中“ $\otimes$ ”代表矩阵点乘，“ $\oplus$ ”代表矩阵相加，“ $\bullet$ ”代表矩阵的拼接，带方向的直线代表数据的具体流动。图中方块代表神经网络层，数据通过各层权重进行数据变换，图中的  $\text{sigm}$  和  $\text{tanh}$  表明该层输出经过 sigmoid、tanh 激活函数处理。

$C(t)$  状态矩阵是 LSTM 神经网络具备记忆功能的关键，该矩阵记录着  $\mathbf{X}$  中每个  $\mathbf{x}(t)$  的信息，实现了对以往输入的记忆。 $C(t)$  在遍历  $\mathbf{X}$  序列后会重新初始化，即网络只会记忆  $N$  个时刻的电压、电流和温度信息。LSTM 的输出  $\mathbf{h}(t)$  矩阵从  $C(t)$  中获取，输出门  $o(t)$  矩阵对  $C(t)$  中的信息进行处理，得到 LSTM 神经网络的输出。

LSTM 循环神经网络通过两个门控单元来实现  $C(t)$  的更新：遗忘门  $f(t)$  矩阵对以往信息进行筛选，即利用  $C(t-1)$  更新  $C(t)$ ；输入门  $i(t)$  矩阵对输入信息进行筛选，利用  $m(t)$  矩阵更新  $C(t)$ 。下列等式展示了具体的转换过程。

$$m(t) = [h(t), x(t)] \quad (1)$$

$$f(t) = \sigma(W_f(t) \cdot m(t) \oplus b_f) \quad (2)$$

$$i(t) = \sigma(W_i(t) \cdot m(t) \oplus b_i) \quad (3)$$

$$o(t) = \sigma(W_o(t) \cdot m(t) \oplus b_o) \quad (4)$$

$$g(t) = \tanh(W_g(t) \cdot m(t) \oplus b_g) \quad (5)$$

$$r(t) = \tanh(W_r(t) \cdot c(t) \oplus b_r) \quad (6)$$

$$c(t) = (c(t-1) \otimes f(t)) \oplus (g(t) \otimes i(t)) \quad (7)$$

以上公式中：“ $\cdot$ ”运算符代表矩阵乘法； $m(t)$  是由  $h(t)$  和  $x(t)$  拼接而成； $\sigma$  代表 sigmoid 函数； $W_f(t)$ 、 $W_i(t)$ 、 $W_o(t)$ 、 $W_g(t)$ 、 $W_r(t)$  分别代表各层权重矩阵， $b_f$ 、 $b_i$ 、 $b_o$ 、 $b_g$ 、 $b_r$  分别代表各层偏置矩阵。

## 1.2 改进的 LSTM 循环神经网络

在 2020 年 ICLR(International Conference on Learning Representations) 国际学习表征会议上，英国牛津大学 Gabor Melis, Tomas Kocisky<sup>[27]</sup> 等人发表了 Mogrifier LSTM(Mg LSTM) 深度学习算法，在

原有 LSTM 的基础上增加两个 sigmoid 门控单元，挖掘输入输出的内在联系，以提高模型的动态逼近能力。改进后的 LSTM 如图 3 所示。

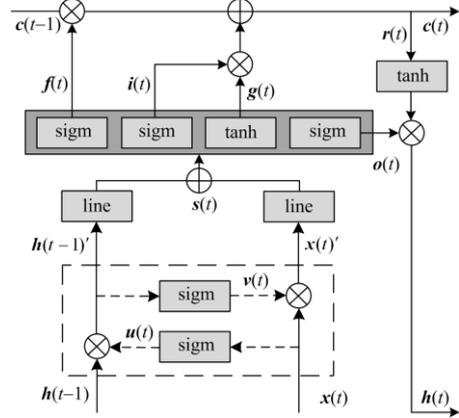


图 3 Mg LSTM 循环神经网络单元

Fig. 3 Mogrifier long short term memory networks unit

图 3 中  $\text{line}$  层代表矩阵的线性变换，即该层输出未经激活函数处理， $W_1$ 、 $W_2$  矩阵代表两个线性层的权重。Mg LSTM 通过  $u(t)$  和  $v(t)$  矩阵控制输入输出的交互，下列等式展示了在原有 LSTM 基础上增加的交互过程。

$$u = \sigma[W_u(t) \cdot x(t) \oplus b_u] \quad (8)$$

$$v(t) = \sigma[W_v(t) \cdot h(t) \oplus b_v] \quad (9)$$

$$h(t-1)' = 2h(t-1) \otimes u(t-1) \quad (10)$$

$$x(t-1)' = 2x(t) \otimes v(t) \quad (11)$$

$$s(t) = (W_1(t) \cdot h(t-1)' \oplus b_{11}) \oplus (W_2(t) \cdot x(t)' \oplus b_{22}) \quad (12)$$

图 3 虚线框内显示了输入和输出的交互过程， $x(t)$  经过权重转换后，经过 sigmoid 函数处理，得到控制状态  $u(t)$ 。sigmoid 函数使得  $u(t)$  中各元素值介于  $[0,1]$ ，将  $u(t)$  和  $h(t-1)$  进行点乘处理，使得  $h(t-1)$  中各元素得到不同程度转换，若  $u(t)$  对应  $h(t-1)$  中的某元素值为 1，则使得  $h(t-1)$  中对应元素按照原数值流入网络，若  $u(t)$  对应  $h(t-1)$  中的某元素值为 0.5，则使得  $h(t-1)$  中对应元素减半后流入神经网络。 $u(t)$  中各元素数值由该层权重处理得出，权重在网络的训练过程中不断更新，以降低网络损失值。

在循环神经网络中，神经网络最后的输出从  $c(t)$  中获取，在网络训练过程中，模型利用一段时间序列的样本对  $c(t)$  进行更新，若  $x(t)$  变化较为剧烈，网络应学会如何对  $x(t)$  进行处理。 $h(t-1)$  通过权重转换，经 sigmoid 函数处理得到  $v(t)$ ，利用  $v(t)$  实现了对  $x(t)$  中各元素转换。网络利用转换后得到的损失值对  $u(t)$  层的权重进行微调，实现梯度更新。将  $h(t-1)$  和  $x(t)$  转换后得到  $h(t-1)'$ 、 $x(t)'$  经过矩阵的

线性变换得到  $s(t)$ , 并将  $s(t)$  分割为四个矩阵, 在此之后, 数据的流动与图 1 中 LSTM 保持一致。

从以上分析可以看出, 通过在 LSTM 基础上加入门控单元  $u(t)$  和  $v(t)$ , 可充分利用输入和输出的内在联系, 增强输入和输出的交互, 提高网络的动态逼近能力。

## 2 实验测试

一般情况下, 深度学习模型无法从完全任意的数据中进行学习, 呈现给模型的数据应该便于模型进行学习。考虑电池电压、放电电流及电池表面温度与 SOC 的映射关系, 本文选用电池电压, 放电电流及电池表面温度作为输入。所选参数在实际工况下便于测量, 可行性较高, 图 4 是本实验流程图。

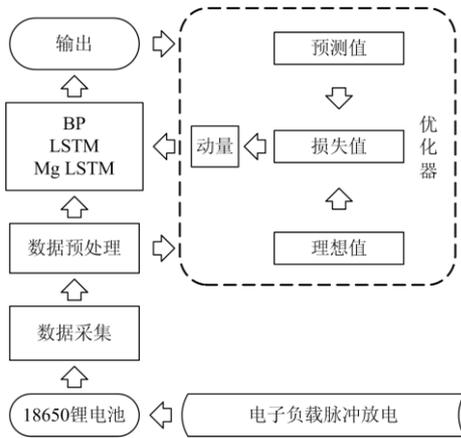


图 4 实验流程图

Fig. 4 Experiment flow chart

### 2.1 数据采集

数据采集平台由 18650 锂电池、电压、电流、温度检测模块、可编程直流电子负载、dSPACE 实验箱、计算机及上位机软件组成。所用锂电池型号为 SONY VTC6, 该电池型号单节电池的最大持续放电电流可达 30 A, 可进行高倍率脉冲放电实验, 电池性能参数如表 1 所示。

首先, 利用直流电子负载对电池进行大倍率脉冲放电。然后, 利用 dSPACE 对电压、电流、温度进行高精度, 高频率采集, 并将采集到的高频电流采用安时积分法计算得到的 SOC 作为理想值。最后, 将 dSPACE 内部高频信号保存到 ControlDesk 上位机软件, 上位机软件以 100 Hz 的频率对电压、电流、温度和 SOC 进行采样, 完成数据采集过程。

本实验在 25℃ 的环境温度下, 电池以 10C 的放电倍率、1 Hz 的脉冲频率、75% 的脉冲宽度进行放电试验。脉冲工况下所获得的电流和电压分别如图

5 和图 6 所示。

表 1 三元锂电池性能参数

Table 1 Performance parameters of lithium-ion batteries

参数	数值
额定容量/Ah	3
最小容量/Ah	2.9
工作电压/V	2.75~3.7
内阻/ $\Omega$	0.012
充电温度/ $^{\circ}\text{C}$	0~45
放电温度/ $^{\circ}\text{C}$	-20~60

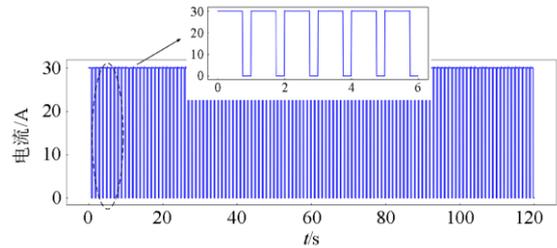


图 5 10C 脉冲工况放电电流

Fig. 5 Current under 10C rate pulsed discharging condition

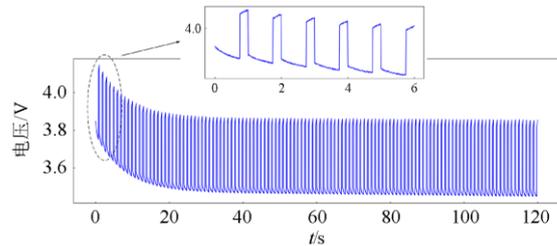


图 6 10C 脉冲工况放电电压

Fig. 6 Voltage under 10C rate pulsed discharging condition

从图中可以看出, 三元锂电池脉冲大倍率放电时所产生的呈非线性特性的极化现象, 该效应受放电倍率影响较大。

将采集得到的数据分为训练集、验证集、测试集。在训练集上训练模型, 在验证集上评估模型并调整网络超参数, 在测试集上测试模型。本实验将电池充满, 放电至 3.35 V 作为一次放电, 对电池重复放电 6 次, 获得 6 组数据, 选取其中 4 组数据作为训练集, 1 组数据作为验证集, 1 组数据作为测试集。

### 2.2 数据预处理

数据进入神经网络之前, 需要进行预处理, 即将电压、电流数值取 [0,1], 以防止较大的梯度更新。本实验采用离差标准化, 是对输入数据的线性变化。转换公式为

$$x'_i = \frac{x_i - X_{\min}}{X_{\max} - X_{\min}} \quad (13)$$

式中： $X_{\max}$ 、 $X_{\min}$  分别代表数据预处理之前电压、电流和温度当中的最大值和最小值。该方法把输入数据压缩到[0,1]，是原始数据的等比压缩。

## 2.3 神经网络搭建

### 2.3.1 模型超参数

本实验神经网络基于 CPU(Intel Core i7-6700k 4 GHz)、GPU(NVIDIA GeForce GTX 1080 8GB)、RAM(16 GB)、Windows10 操作系统和 PyTorch 深度学习框架搭建。

在深度学习中，模型中可学习参数的个数被称为模型的容量，参数更多的模型拥有更大的记忆容量，能够在训练样本和目标之间轻松地学会完美的映射，但这种映射没有任何泛化能力，容易造成过拟合现象。防止过拟合的最简单的方法就是减小模型大小，即减少模型中可学习参数的个数，但模型过小会导致网络无法学习全部特征，需要在容量过大与容量不足之间要找到一个折中。

经多次测试，将 BP 神经网络隐含层设为三层，各层节点数分别为 128、128、64 个。LSTM 和 Mg LSTM 由 4 个输入节点、32 个隐藏层节点、1 个全连接层和 1 个输出节点构成。以上模型均在全部训练数据上训练 1 000 次。

### 2.3.2 损失函数

本实验采用均方误差 (Mean Squared Error, MSE) 作为损失函数，用其检测预测值和理想值之间的偏差。

$$MSE = \frac{1}{N} \sum_{i=1}^N (f_i - y_i)^2 \quad (14)$$

式中： $f_i$  为预测值； $y_i$  为理想值； $N$  为批处理数值。在本次实验中， $N$  取值为 128。在模型的训练过程中通过批处理进行学习，利用 GPU 的多线程处理能力，加速网络的训练过程。在训练周期一定的情况下， $N$  取值过小会造成训练速度过慢，取值过大会导致网络学习次数不足，即权重的更新次数过少。

### 2.3.3 优化器

优化器利用损失函数得到的损失值对各层权重进行微调，以降低当前输入的损失值。由于网络参数较多，在权重梯度下降的过程中经常会存在局部极小点，在局部极小点附近，权重的微调会导致损失值增大，优化过程很可能会陷入局部极小点，导致无法找到全局最小点。

为避免模型陷入局部最小点，本实验选用带动量的小批量梯度下降作为优化器，该方法将优化过程想象成从损失函数曲线上滚下来的小球，如果小球的动量足够大，则小球不会卡在局部最小点，最终会达到全局最小点。在模型中指的是权重的更新

不仅要考虑当前的梯度值，还要考虑上一次的梯度值。

## 3 实验结果分析

### 3.1 数据集估算结果

在 10C 的放电倍率，1 Hz 的脉冲频率，75% 的脉冲宽度放电形式下，BP、LSTM 和 Mg LSTM 的预测结果如图 7 所示，从图中可以看出，Mg LSTM 预测性能最佳，其预测曲线与理想曲线基本重叠。LSTM 的预测误差在前 20 s 较为明显，自 150 s 后呈放大趋势。BP 神经网络受脉冲影响最为明显，其最大误差超过 30%，表明在脉冲大倍率放电工况下，BP 神经网络利用单一时刻输入进行预测，无法准确表征三元锂电池的工作特性。

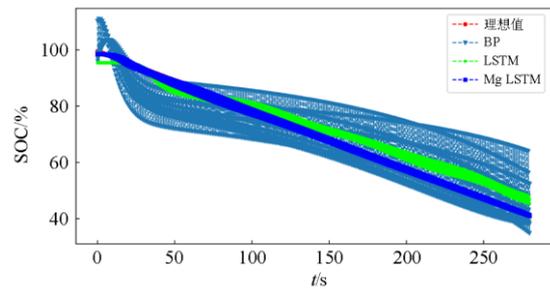


图 7 BP、LSTM、Mg LSTM 预测结果

Fig. 7 BP, LSTM, Mg LSTM estimation results

图 8 是预测曲线前 50 s 局部放大图，从图中可以看出，在预测的前 10 s，BP 和 LSTM 神经网络难以表征电池工作特性。Mg LSTM 与 LSTM 相比较，拟合精度更高，性能更为稳定。

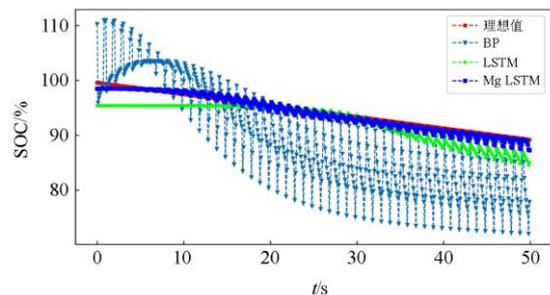


图 8 局部放大图

Fig. 8 Partial enlarged drawing

### 3.2 不同放电倍率下实验结果

3.1 节已经验证了 Mg LSTM 算法在 10C 的放电倍率、1 Hz 的脉冲频率、75% 的脉冲宽度放电形式下 SOC 估算的精确性，为检验算法的泛化能力，分别在以下两种工况条件下验证 SOC 估算的精度。工况一：采用 10C 脉冲放电，脉冲频率 0.2 Hz，脉冲宽度 20%，脉冲放电 10 次；工况二：采用 5C 脉冲

放电, 脉冲频率 0.25 Hz, 脉冲宽度 25%, 脉冲放电 12 次。

从图 9 可以看出, Mg LSTM 与 LSTM 相比, 预测波形的峰谷值较小, 拟合精度更高。在不同工况下, Mg LSTM 稳态误差均不超过 2%, 验证了算法的泛化能力。

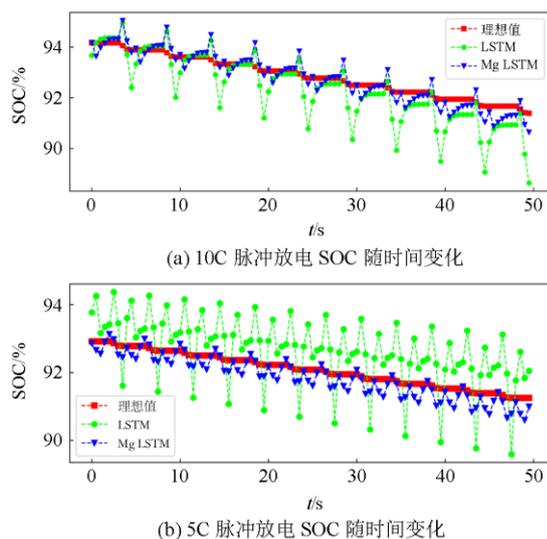


图 9 SOC 估算结果

Fig. 9 Results of SOC estimation

## 4 结论

为提高锂电池 SOC 估计的精确度, 本文提出了一种基于改进 LSTM 的锂电池 SOC 估算方法, 该方法在 LSTM 基础上加入两个门控单元, 以增强网络的动态逼近能力。在脉冲大倍率放电工况下, 验证了改进方法的有效性。实验结果表明, 改进算法与原有 LSTM 神经网络相比较, 能更好表征锂电池的工作特性, 拟合精度更高, 验证了算法的可行性。

## 参考文献

- [1] 明彤彤, 王凯, 田冬冬, 等. 基于 LSTM 神经网络的锂离子电池荷电状态估算[J]. 广东电力, 2020, 33(3): 26-33.  
MING Tongtong, WANG Kai, TIAN Dongdong, et al. State of charge estimation of lithium ion battery based on LSTM neural network[J]. Guangdong Electric Power, 2020, 33(3): 26-33.
- [2] 程俊, 曲妍, 李媛, 等. 基于剩余电量估计的电池组充放电均衡策略[J]. 电力系统保护与控制, 2020, 48(3): 122-129.  
CHENG Jun, QU Yan, LI Yuan, et al. Equalization strategy of battery pack charge and discharge based on residual power estimation[J]. Power System Protection and Control, 2020, 48(3): 122-129.
- [3] 崔红芬, 杨波, 蒋叶, 等. 基于模糊控制和 SOC 自恢复储能参与二次调频控制策略[J]. 电力系统保护与控制, 2019, 47(22): 89-97.  
CUI Hongfen, YANG Bo, JIANG Ye, et al. Secondary frequency modulation control strategy based on fuzzy control and SOC self recovery energy storage[J]. Power System Protection and Control, 2019, 47(22): 89-97.
- [4] ZHENG Y, OUYANG M, HAN X, et al. Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles[J]. Journal of Power Sources, 2018, 377: 161-188.
- [5] 刘俊华, 张启超, 李程, 等. 磷酸铁锂电池模组健康度快速评估方法研究[J]. 电网与清洁能源, 2020, 36(10): 112-118.  
LIU Junhua, ZHANG Qichao, LI Cheng, et al. Study on the rapid assessment method of health of lithium iron phosphate battery module [J]. Power System and Clean Energy, 2020, 36(10): 112-118.
- [6] HERATH A, KODITUWAKKU S, DASANAYAKE D, et al. Comparison of optimization- and rule-based EMS for domestic PV-battery installation with time-varying local SOC limits[J]. Journal of Electrical and Computer Engineering, 2019, 2019: 1-14.
- [7] 和萍, 祁盼, 申润杰, 等. 计及风电和燃料电池的综合能源系统阻尼特性分析[J]. 电力科学与技术学报, 2020, 35(1): 14-23.  
HE Ping, QI Pan, SHEN Runjie, et al. Damping analysis of integrated energy system considering wind power and fuel cell[J]. Journal of Electric Power Science and Technology, 2020, 35(1): 14-23.
- [8] GAO Z C, CHIN C S, TOH W D, et al. State-of-charge estimation and active cell pack balancing design of lithium battery power system for smart electric vehicle[J]. Journal of Advanced Transportation, 2017, 2017: 1-14.
- [9] CHEN W, LIANG J, YANG Z, et al. A review of lithium-ion battery for electric vehicle applications and beyond[J]. Energy Procedia, 2019, 158: 4363-4368.
- [10] 王凯, 夏国廷, 李立伟, 等. 边缘检测和证据理论在机器人目标识别中的应用[J]. 实验室研究与探索, 2019, 38(3): 29-33.  
WANG Kai, XIA Guoting, LI Liwei, et al. Application of edge detection and evidence theory in robot target recognition[J]. Research and Exploration in Laboratory, 2019, 38(3): 29-33.
- [11] 孔顺飞, 胡志坚, 谢仕炜, 等. 考虑分布式储能与电动汽车充电网络的配电网多目标规划[J]. 电力科学与技术学报, 2021, 36(1): 106-116.

- KONG Shunfei, HU Zhijian, XIE Shiwei, et al. Multi objective distribution network planning considering distributed energy storage and electric vehicle charging network[J]. Journal of Electric Power Science and Technology, 2021, 36(1): 106-116.
- [12] CHEMALI E, KOLLMAYER 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.
- [13] ZOU C F, HU X S, DEY S D, et al. Nonlinear fractional-order estimator with guaranteed robustness and stability for lithium-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5951-5961.
- [14] DEY S, AYALEW B, PISU P. Nonlinear robust observers for state of charge estimation of lithium-ion cells based on a reduced electrochemical model[J]. IEEE Transactions on Control Systems Technology, 2015, 23(5): 1935-1942.
- [15] 王凯, 周圣哲, 李玉浩, 等. 电力电子技术多元化创新型教学模式探索[J]. 实验室研究与探索, 2019, 38(7): 173-175.
- WANG Kai, ZHOU Shengzhe, LI Yuhao, et al. Exploration on diversified and innovative teaching mode of power electronic technology[J]. Research and Exploration in Laboratory, 2019, 38(7): 173-175.
- [16] CHEN X, SHEN W, DAI M, et al. Robust adaptive sliding-mode observer using RBF neural network for lithium-ion battery state of charge estimation in electric vehicles[J]. IEEE Transactions on Vehicular Technology, 2016, 65(4): 1936-1947.
- [17] HOU J, YANG Y, HE H, et al. Adaptive dual extended Kalman filter based on variational Bayesian approximation for joint estimation of lithium-ion battery state of charge and model parameters[J]. Applied Sciences, 2019, 9(9): 17-26.
- [18] 张振宇, 汪光森, 聂世雄, 等. 脉冲大倍率放电条件下磷酸铁锂电池荷电状态估计[J]. 电工技术学报, 2019, 34(8): 1769-1779.
- ZHANG Zhenyu, WANG Guangsen, NIE Shixiong, et al. State of charge estimation of lithium iron phosphate battery under pulse high rate discharge[J]. Transactions of China Electrotechnical Society, 2019, 34(8): 1769-1779.
- [19] MA Yan, DUAN Peng, SUN Yanshuai, et al. Equalization of lithium-ion battery pack based on fuzzy logic control in electric vehicle[J]. IEEE Transactions on Industrial Electronics, 2018, 65(8): 6762-6771.
- [20] WEI Z, MENG S, XIONG B, et al. Enhanced online model identification and state of charge estimation for lithium-ion battery with a FBCRLS based observer[J]. Applied Energy, 2016, 181: 332-341.
- [21] YE M, GUO H, XIONG R, et al. Model-based state-of-charge estimation approach of the lithium-ion battery using an improved adaptive particle filter[J]. Energy Procedia, 2016, 103: 394-399.
- [22] 刘淑杰, 郝昆昆, 王永, 等. 基于改进粒子滤波算法的动力锂离子电池荷电状态估计[J]. 大连理工大学学报, 2020, 60(4): 392-401.
- LIU Shujie, HAO Kunkun, WANG Yong, et al. State of charge estimation of power lithium ion battery based on improved particle filter algorithm[J]. Journal of Dalian University of Technology, 2020, 60(4): 392-401.
- [23] ALVAREZ J C, GARCIA NIETO P J, BLANCO V C, et al. Support vector machines used to estimate the battery state of charge[J]. IEEE Transactions on Power Electronics, 2013, 28(12): 5919-5926.
- [24] HU J N, HU J J, LIN H B, et al. State-of-charge estimation for battery management system using optimized support vector machine for regression[J]. Power Sources, 2014, 269: 682-693.
- [25] 李超然, 肖飞, 樊亚翔, 等. 一种基于 LSTM-RNN 的脉冲大倍率工况下锂离子电池仿真建模方法[J]. 中国电机工程学报, 2020, 40(9): 3031-3042.
- LI Chaoran, XIAO Fei, FAN Yaxiang, et al. A simulation modeling method of lithium ion battery under high pulse rate based on LSTM-RNN[J]. Proceedings of the CSEE, 2020, 40(9): 3031-3042.
- [26] GUO Y, ZHAO Z, HUANG L. SOC estimation of lithium battery based on improved BP neural network[J]. Energy Procedia, 2017, 105: 4153-4158.
- [27] MELIS G, KOCISKY T, BLUNSOM P. Mogrifier LSTM[C] // International Conference on Learning Representations, April 30, 2020, Addis Ababa, Ethiopia.

收稿日期: 2020-07-03; 修回日期: 2021-03-02

作者简介:

明彤彤(1994—), 男, 硕士研究生, 研究方向为锂电池荷电状态估计, 深度学习; E-mail: 598473176@qq.com

王凯(1985—), 男, 通信作者, 特聘教授, 硕士生导师, 研究方向为储能系统, 能源互联网。E-mail: kwkj888@163.com

(编辑 姜新丽)