

基于 EMD-GRU 的锂离子电池荷电状态估计

李宁¹ 何复兴¹ 马文涛¹ 蒋林² 张小平³

(1. 西安理工大学电气工程学院 西安 710048

2. 利物浦大学电气工程和电子系 利物浦 英国 L69 3GJ

3. 伯明翰大学电子、电气和系统工程系 伯明翰 英国 B15 2TT)

摘要 锂离子电池荷电状态(State Of Charge, SOC)估计技术是电动汽车电池监测系统(Battery Management System, BMS)设计的重要组成部分。准确的SOC估计可避免锂离子电池过度充电和过度放电,提高放电效率并延长循环寿命。本文提出一种基于EMD-GRU的锂离子电池荷电状态估计,在门控循环单元(Gate Recurrent Unit, GRU)估计SOC的基础上,引入经验模态分解(Empirical Mode Decomposition, EMD)算法分解放电电流,提高GRU模型对长时间电流信号保持长期信息的能力,提高锂离子电池荷电状态估计精度。仿真实验表明,与传统的循环神经网络和长短期记忆网络相比,本文所提EMD-GRU方法的锂离子电池SOC估计平均绝对误差在1.5093%,同比降低了20.7924%。

关键词: 锂离子电池 荷电状态估计 门控循环单元 经验模态分解

中图分类号: TM 912

State-of-charge estimation of lithium-ion battery based on EMD-GRU

Li Ning¹ He Fuxing¹ Ma Wentao¹ Jiang Lin² Zhang Xiaoping³

(1. School of Electrical Engineering, Xi'an University of Technology Xi'an 710048 China

2. Department of Electrical Engineering and Electronics, University of Liverpool
Liverpool L69 3GJ United Kingdom

3. Department of Electronics, Electrical and Systems Engineering, University of Birmingham,
Birmingham B15 2TT United Kingdom)

Abstract Lithium-ion battery state of charge (SOC) estimation technology is an important part of the design of an electric vehicle battery management system (BMS). Accurate SOC estimation can avoid overcharge and overdischarge of lithium-ion batteries, improve discharge efficiency and extend cycle life. In this paper, an EMD-GRU based SOC estimation for lithium-ion batteries is proposed. Based on the gated recurrent unit (GRU) estimation of the SOC, the empirical mode decomposition (EMD) algorithm is introduced to decompose the discharge current, improve the ability of the GRU model to maintain long-term information for long-term current signals, and improve the accuracy of lithium-ion battery SOC estimation. Simulation experiments show that, compared with the traditional recurrent neural network and long short term memory network, the average absolute error of the lithium-ion battery SOC estimation of the EMD-GRU method proposed in this paper is 1.5093%, a year-on-year decrease of 20.7924%.

Keywords: lithium-ion battery, state of charge estimation, gate recurrent unit, empirical mode decomposition

0 引言

石油能源的枯竭推动了新能源电动汽车的蓬勃发展。2021年百度、小米和华为也开始进军电动汽车产业，锂离子电池作为电动汽车动力电池的需求将会越来越大。然而安全性和续航里程问题制约了电动汽车的发展，许多车企研发锂离子电池管理系统（Battery Management System, BMS），以检测电池温度并保护汽车安全稳定运行^[1]。

锂离子电池的荷电状态（State Of Charge, SOC）的准确评估和预测是 BMS 的关键功能之一。一般的，SOC 定义为剩余容量与当前最大可用容量的百分比，主要为 BMS 系统提供充放电测量参考，防止电池过充和过放^[2]。由于单体电池的制造工艺和使用环境不同，导致电池性能存在差异，会影响到整个电池组的效率，因此 BMS 主要通过监控每个单体电池 SOC，合理地每个单体电池充放电，补偿电池之间的差异。然而，由于复杂多变的负载和环境，电池 SOC 往往不能通过直接测量其内部状态参数求得，需要采用外部参数构建的模型对 SOC 进行估计，这种采用外部参数构建的模型成为了 SOC 估计的研究热点^[3]。

现有的 SOC 估计方法主要有：按时积分法^[4]、开路电压法^[5]、内阻法^[6]、滤波法^[7-9]和神经网络算法^[10-12]等。随着计算机硬件及信息技术的发展，滤波方法和神经网络方法成为锂离子电池的研究热点，神经网络模型相比于其他方法具有如下优点：1) 电池测量数据直接映射到 SOC 值，而无需依赖于运行参数的其他电池模型；2) 通过梯度下降算法学习权重和偏差，这与需要大量努力进行人工设计和参数化的数学模型大不相同；3) 具有一组网络参数的神经网络模型可以在各种环境温度下实现 SOC 估计，而其他传统方法则需要针对不同的工作条件具有不同参数的模型。因此，本文采用基于神经网络模型进行锂离子电池 SOC 估计。

常见的应用于 SOC 估计的神经网络法有支持向量机法和前馈式神经网络法^[11,12]。但是，这两种方法在 SOC 估计中也有些缺陷：1) 输入数据及特征需要人为进行设计和提取，花费大量的时间；2) 模型结构采用浅层学习架构，这些架构的分析能力不足并且难以处理高维数据。

深度神经网络可用于解决上述问题，通过使用多次非线性变换构建深度神经网络（Deep Neural Network, DNN），从输入数据中分层提取复杂的特

征信息。近年来，已经提出了几种基于 DNN 的 SOC 估计方法。文献[13]使用多层感知器（Multi-layered perceptron, MLP）网络构造了 SOC 估计器，并使用不同环境温度下测得的信号训练了该估计器。结果表明训练后的模型可以减小 SOC 的估计误差。在这项研究的基础上，考虑到长短期记忆网络（Long Short-Term Memory, LSTM）在时间序列数据中捕获时间信息方面的优势，文献[14, 15]开发了一种基于 LSTM 的 SOC 估计器，以进一步提高估计精度，并取得了良好的效果。作为循环神经网络（Recurrent neural network, RNN）的另一个变体，门控循环单元（Gate Recurrent Unit, GRU）网络也已应用于 SOC 估计。文献[16,17]将 GRU 结构引入 RNN 网络，以提高锂离子电池非线性行为的建模能力，并分别构建了两个使用电流和电压信号作为输入的模型来进行 SOC 估计。然而上述文献未考虑变工况条件下的锂离子电池 SOC 估计，并且在长时间序列信号下会降低 SOC 的估计精度。

为解决上述问题，本文提出一种基于 EMD-GRU 的锂离子电池荷电状态估计，首先对比分析了 RNN、LSTM 和 GRU 在锂离子电池 SOC 估计中的应用，证明 GRU 模型相比其他两种方法更适用于 SOC 估计；其次研究了不同温度变工况条件下 GRU 锂离子电池 SOC 估计模型；最后提出一种 EMD-GRU 锂离子电池 SOC 估计方法，将电流信号分为趋势电流、周期电流和波动电流信号，提高了 GRU 面临长时间序列信号的能力，进而提高锂离子电池在 SOC 估计精度。

1 门控循环神经网络

传统的前馈神经网络缺乏使用历史信息的能力，然而这些历史信息在序列问题中显得至关重要，例如短语或句子的翻译，以及视频输入生成标题等。此外，传统的前馈神经网络无法处理具有可变输入和输出大小的时序信号。与前馈神经网络不同，门控循环神经网络使用循环单元来存储和处理历史信息，能有效克服前馈神经网络缺记忆能力的问题^[18]。

1.1 循环神经网络

如图 1 所示，循环单元有一个反馈回路，隐藏状态 h_k 更新为：

$$h_k = \begin{cases} 0 & k=0 \\ \Phi(h_{k-1}, x_k) & otherwise \end{cases} \quad (1)$$

其中 x_k 是第 k 个输入向量， ϕ 是非线性函数。实际上，等式 (1) 中的隐藏状态的更新被实现为：

$$h_k = g(W_h \cdot [h_{k-1}, x_k] + b_h) \quad (2)$$

其中 g 是平滑有界的激活函数，例如 sigmoid 函数或 tanh 函数； W_h 是隐藏层和输入层之间的权重矩阵； b_h 是表示每个节点的偏移量的偏差参数。然后可以通过以下方式获得相应的输出 y_k 。




图 1 RNN 结构图

Fig.1 Structure of the RNN

$$y_k = g(W_h \cdot h_k + b_y) \quad (3)$$

时间步长的递归边缘使 RNN 在处理诸如连接文字或语音识别之类的任务方面表现出色。然而当序列变长时，会出现梯度消失或梯度爆炸的问题，难以训练 RNN。为了解决这一问题，可以设计一种新的激活函数如 LSTM 和 GRU^[16,17,19]，GRU 相比于 LSTM 参数和结构更为简单，在较小的数据集上性能优于 LSTM，因此本文采用 GRU 进行锂离子电池 SOC 估计。

1.2 门控循环单元

GRU 先前的隐藏状态 h_{k-1} 和当前输入 x_k 不会直接影响标准 RNN 中的当前隐藏状态 h_k 。取而代之的是，GRU 使用更新门来确定应该传递多少过去的信息，并使用重置门来确定要丢弃多少信息。

图 2 表示 GRU 的一般结构，其中，GRU 的激活是先前状态 h_{k-1} 和候选状态 \tilde{h}_k 的线性组合：

$$h_k = (1 - z_k) \cdot h_{k-1} + z_k \cdot \tilde{h}_k \quad (4)$$

式中， z_k 称为更新门，由 Sigmoid 函数激活。

$$z_k = \sigma(W_z \cdot [h_{k-1}, x_k]) \quad (5)$$

如果 z_k 数值接近于 1，则当前状态更多地取决于候选状态，而如果 z_k 数值接近 0，则当前状态更依赖于先前状态。直观地， z_k 确定应接受多少比例

的候选状态。

GRU 的候选状态计算如下：

$$\tilde{h}_k = \tanh(W_h \cdot [r_k \cdot h_{k-1}, x_k]) \quad (6)$$

式中， r_k 称为的重置门，由 Sigmoid 函数激活。

$$r_k = \sigma(W_r \cdot [h_{k-1}, x_k]) \quad (7)$$

与更新门类似，重置门可以限制先前的隐藏状态对候选状态的影响。

虽然标准 RNN 循环单元以指数移动平均方式更新，但 GRU 可以决定更新什么，重置什么。此外，如果门控因子接近 1，隐藏单元的输出会沿着扩展链流动很长的距离。同时，梯度消失现象也可以大大避免，因为误差也可以反向传播许多时间步骤。随后，捕获长期依赖关系成为可能。

标准 RNN 循环单元以指数移动平均方式进行更新，而 GRU 可以决定要更新的内容和重置的内容。此外，如果门控因子接近 1，则隐藏的单元输出将沿着扩展链流动很长的距离。同时，由于误差还可以反向传播许多时间步骤，因此也可以有效避免梯度消失现象。随后，捕获长期依赖性成为可能。




图 2 GRU 结构图

Fig.2 Structure of the GRU

2 经验模态分解

传统的 GRU 网络进行锂离子电池 SOC 估计时采用电流、电压、温度作为网络输入，SOC 作为网络输出。然而在面临较长时间序列时，会出现丢失部分中长期序列信息的情况，影响模型预测精度。因此本文为了提高 GRU 网络面对较长时间序列时保存趋势信号的能力，采用经验模态分解(Empirical Mode Decomposition, EMD)^[20]算法进行电流信号的预处理。将电流信号分解为若干个电流子序列，提取出长时低频电流信号，剔除了电流中的噪声数据，

并结合电压和温度组成网络模型的输入,提高 GRU 模型估计精度。

EMD 是一种信号处理方法,主要应用于非平稳信号的预处理。该方法相比于小波分解,不需要提前设定任何基函数,具有自适应特性。分解得到的子序列集被称作固有模态函数 (Intrinsic Mode Function, IMF)。EMD 具体分解的步骤如下:

首先,确定出原始电流时间序列 $i(t)$ 的所有极值点,采用三次样条插值法进行上包络线 $u(t)$ 和下包络线 $d(t)$ 拟合。并计算出上下包络线均值曲线 $m_1(t)$:

$$m_1(t) = \frac{u(t) + d(t)}{2} \quad (8)$$

将 $m_1(t)$ 从原始电流时间序列 $i(t)$ 移除,得到一个新的时间序列 $n_1(t)$:

$$n_1(t) = i(t) - m_1(t) \quad (9)$$

判断新的时间序列 $n_1(t)$ 是否满足 IMF 两个基本条件,如果满足,那么它就是所求的 IMF 分量。如果不满足条件,对 $n_1(t)$ 重复以上步骤,直到移除均值曲线后的分量 $n_{1k}(t)$ 满足 IMF 的基本条件:

$$n_{1k}(t) = n_{1(k-1)}(t) - m_{1k}(t) \quad (10)$$

那么 $n_{1k}(t)$ 是最小时间尺度的 IMF 分量,记为 $c_1(t)$:

$$c_1(t) = n_{1k}(t) \quad (11)$$

且满足如下停止准则:

$$SD = \sum_{t=0}^T \frac{|n_{1(k-1)}(t) - n_{1k}(t)|^2}{n_{1(k-1)}^2(t)} \leq \varepsilon \quad (12)$$

其中, T 为时间序列的长度, ε 设置在 0.2~0.3。SD 是两个连续筛选结果计算的标准偏差。

将 $c_1(t)$ 从原始时间序列 $i(t)$ 中去除,得到残余序列 $r_1(t)$:

$$r_1(t) = i(t) - c_1(t) \quad (13)$$

再把 $r_1(t)$ 作为新的时间序列重复以上步骤,获得新的 IMF 分量,直到残余序列 $r_n(t)$ 为恒定值或者单调函数时,分解结束。

综上,原始时间序列 $i(t)$ 被分解成 n 个 IMF 和一个残余序列 $r_n(t)$, 可表示为:

$$i(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (14)$$

锂离子电池实际运行中电压和温度变化相对缓

慢,是一个平稳信号,充电时电压上升,放电时电压下降,温度在充放电过程都会上升。然而其电流随着速度的变化而变化,是一个不平稳信号,因此只需要对电流进行 EMD 分解。EMD 分解的流程图如图 3 所示。

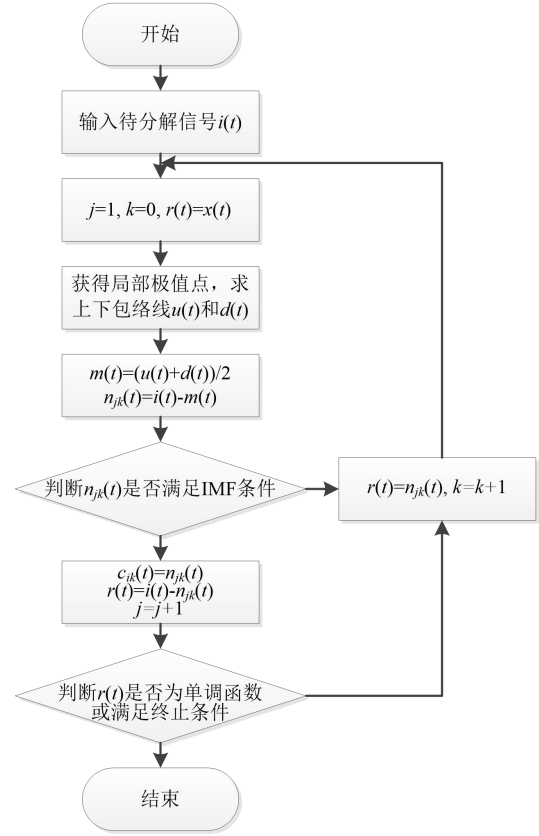


图 3 EMD 算法流程图

Fig.3 EMD algorithm flow chart

3 EMD-GRU 的锂离子电池 SOC 估计模型

基于前文对 EMD 和 GRU 算法的介绍,提出一种基于 EMD-GRU 锂离子电池 SOC 估计方法,如图 4 所示。该方法采用 EMD 算法对电池电流信号进行分解,把电流分解为若干个电流子序列,然后结合电池电压和电池温度波动作为 GRU 神经网络输入,经过全连接层网络后,电池 SOC 作为输出。已有的数据进行模型训练,得到模型参数,引入新的电流子序列、电压和温度作为网络输入,预测网络的 SOC。

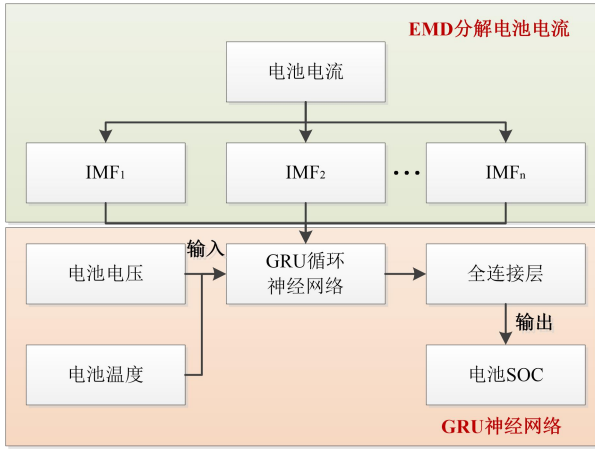


图 4 EMD-GRU 锂离子电池 SOC 估计方法

Fig.4 EMD-GRU Lithium-ion battery SOC estimation method

EMD-GRU 锂离子电池 SOC 估计具体步骤如下:

1)数据预处理。数据的准确性决定着网络模型的准确性,收集电流、电压、温度 $x_k=[I_k, V_k, T_k]$ 和 SOC 数据 $y_k=[SOC_k]$,完成错误及缺失数据的修正,划分训练集和测试集。

2)经验模态分解。采用 EMD 将电流信号 I_k 分为子电流序列集合 $[I_{1k}, I_{2k}, \dots, I_{jk}]$ 。考虑到分解后的电流序列数值单位相差较大,采用 min-min 归一化电流子序列集,将数值缩放到 0 到 1 之间。

$$I_{ik}^* = \frac{I_{ik} - \min(I_{ik})}{\max(I_{ik}) - \min(I_{ik})} \quad i=1,2,\dots,j \quad (15)$$

式中, I_{ik}^* 为归一化后的电流子序列集。

3)GRU 模型时序预测。采用训练集数据建立基于 GRU 的锂离子电池 SOC 估计模型,通过设定网络结构及参数,Adam 作为网络的训练优化算法,ReLU 作为网络激活函数,均方误差函数作为优化目标函数,进而训练得到最优的 SOC 估计模型参数。

4)模型评价。测试集作为 GRU 模型的输入,得到估计的 SOC 值,进而通过预测值和实际值的误差度量模型准确性,选用平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Square Error, MSE)、均方根误差 (Root Mean Square Error, RMSE)。计算公式如(16)~(18)所示,其中 \hat{y}_i 为第 i 个预测值, y_i 为第 i 个实际值, n 为预测数量。

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (18)$$

4 仿真实验结果

4.1 电池实验和数据收集

电动汽车的实际行驶条件是复杂而不确定的。为了尽可能地模拟电动汽车的真实驾驶条件,训练数据需要推广到其他驾驶条件。本文使用了来自美国马里兰大学高级生命周期工程中心(Center for Advanced Life Cycle Engineering, CALCE)的数据仓库的公共数据集^[21]。

试验中,将 A123 型号的电池放置在温度室中,进行充放电,A123 型号电池是详细参数见表 1。测量电流和测量电压如图 5 所示,(a)~(c)为测量电流,(d)~(f)为测量电压。动态应力测试 DST 数据集(图 5a 和图 5d)与联邦城市驾驶时间表 FUDS 数据集(图 5b 和图 5e)和 US06 数据集(图 5c 和图 5f)都不同。DST 和 FUDS 与 US06 在放电电流和电压上有明显的差异,由于训练数据往往多于测试数据,因此本文以 DST 和 FUDS 数据集作为训练数据集,US06 作为测试数据集。DST、FUDS 和 US06 数据集的温度为 10℃、20℃、30℃和 40℃。




图 5 测量电流和测量电压图

Fig.5 Measurement Current and measurement voltage diagram

表 1 A123 型号电池的详细参数
Tab.1 Detailed parameters of A123 battery

参数	规格
额定容量	2230mAh
化学成分	LiFePO4
重量	76g
尺寸	25.4 mm
长度	65 mm

4.2 GRU 模型锂离子电池 SOC 估计结果

为了验证 GRU 模型是否适用于锂离子电池 SOC 估计，对比分析了 RNN 模型和 LSTM 模型仿真结果。网络模型和参数统一为表 2 给出的数据，首先需要确定迭代次数，本文采用常温 20°C 下进行迭代次数的选择，如表 3 和图 6 分别为三种循环神经网络锂离子电池 SOC 估计迭代次数和误差之间的关系。

表2 网络模型结构及参数
Tab.2 Network model structure and parameters

时间步长	30
训练批量大小	3000
隐含层层数	2
隐含层节点个数	32
激活函数	ReLu
训练优化算法	Adam
初始学习率	0.01
优化目标函数	MSE

表3 迭代次数与误差关系表(训练MSE/%)

Tab.3 The relationship between the number of iterations and the error (training MSE/%)

迭代次数	10	20	30	40
RNN	2.0684	2.2031	0.5773	0.3439
LSTM	3.7263	1.2807	0.2300	0.1923
GRU	3.1176	1.0799	0.7875	0.2047
迭代次数	50	100	200	300
RNN	0.2208	0.5388	0.2186	8.6307

LSTM	0.1081	0.0440	0.0299	0.0165
GRU	0.1218	0.0266	0.0103	0.0041
每次迭代	RNN	LSTM	GRU	
平均时间/s	0.3876	1.2828	0.9778	

表 3 可以看出刚开始 10 次迭代阶段，RNN 的精度较高，LSTM 和 GRU 相对误差较高，这与网络随机初始化参数有关联，RNN 初始化的参数更加接近与最优参数。当迭代次数达到 20 次，LSTM 和 GRU 这两个变种循环网络的精度已经高于传统的 RNN。RNN 在迭代次数 50 附近达到最优，然而在后面迭代次数由于过拟合导致模型误差升高，因此 RNN 模型实验迭代次数不易过多。LSTM 和 GRU 随着迭代次数的增加，误差持续降低，然而所求误差是训练误差，不能反映实际测试误差，当训练误差远远小于电池测试仪器的测试精度 0.05% 时，将会过度拟合电池测量仪器噪声。




图 6 迭代次数与误差关系图

Fig.6 The relationship between the number of iterations and the error

图 6 可以明显的看出：三种算法迭代次数在 50 次时收敛在较高的精度；迭代的 MSE 关系为 GRU<LSTM<RNN；迭代次数在 100 次时的误差在 0.05% 附近，因此为了防止过拟合，本文后面实验部分迭代次数固定为 100。

表 4 所示 GRU 模型锂离子电池不同温度下 SOC 估计误差，MAE 在 1.9055%，MSE 在 0.0655%，RMSE 在 2.5085%。MAE 满足在 2% 以内，已经满足诸多 SOC 估计的需求。如图 7 所示 GRU 模型锂离子电池不同温度 SOC 估计结果，其估计误差值波动幅值较小，波动的频率平缓，估计波动趋势和图 5 电流波动趋势相近。

表4 GRU模型锂离子电池不同温度下SOC估计误差

Tab.4 GRU model lithium-ion battery SOC estimation error at

different temperatures

温度	MAE(%)	MSE(%)	RMSE(%)
10℃	1.7388	0.0487	2.2072
20℃	1.6082	0.0498	2.2322
30℃	1.7196	0.0483	2.1978
40℃	2.5553	0.1153	3.3966
平均	1.9055	0.0655	2.5085




图 7 GRU 模型锂离子电池不同温度 SOC 估计结果

Fig.7 GRU model lithium-ion battery SOC estimation results at different temperatures

4.3 EMD-GRU 模型锂离子电池 SOC 估计结果

由 4.2 节实验可以得出，SOC 估计趋势和充放电电流信号是最为相关的。为了更深入地研究电流对 SOC 的影响，提高其估计精度，本文对充放电电流进行 EMD 分解，这里采用 20℃ 数据进行分解，如图 8 所示为基于 EMD 算法分解锂离子电池充放电电流过程图，图中(a)~(h)分别代表第 1 到第 8 个 IMF 分量。其中 IMF1~IMF3 频率较高，表现出非常强的随机性与波动性，因此可以体现电流的波动性，IMF4~IMF6 随机性降低，呈现出一定的周期性，IMF7 和 IMF8 基本平稳，故可体现电流的长期趋势。图 9 为 EMD 分解后残差电流，可以看出残差电流单位与正常电流信号差异已经小于 1%，因此可以不用作为 GRU 网络的输入。

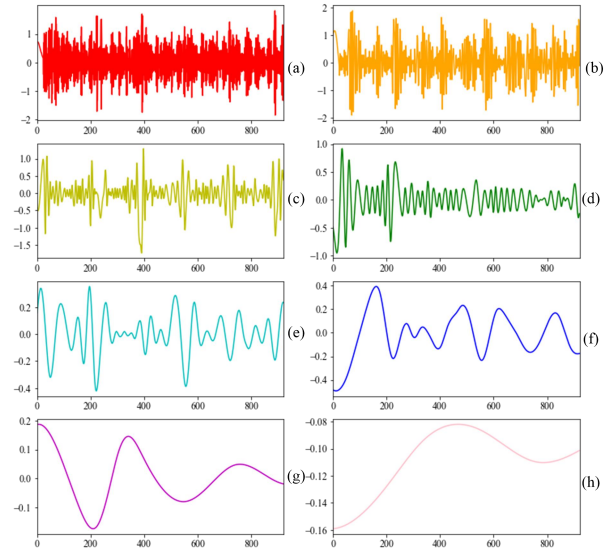


图 8 EMD 分解的锂离子电池充放电电流

Fig.8 Charge and discharge current of Lithium-ion battery decomposed by EMD




图 9 EMD 分解的锂离子电池充放电电流残差

Fig.9 The residual charge and discharge current of lithium-ion battery decomposed by EMD

表5 EMD-GRU模型锂离子电池SOC估计误差

Tab.5 EMD-GRU model lithium-ion battery SOC estimation error

方法	MAE(%)	MSE(%)	RMSE(%)
RNN	3.0467	0.1483	3.8387
LSTM	2.2537	0.0913	3.0111
GRU	1.9055	0.0655	2.5085
EMD-GRU	1.5093	0.0375	1.9303

表 5 所示为 EMD-GRU 模型锂离子电池 SOC 估计误差，相比于 RNN 和 LSTM 在三种误差指标都有一定的提升，MAE 在 1.5093%，同比于 GRU 模型误差降低了 20.7924%，MSE 在 0.0375%，同比

于 GRU 模型误差降低了 42.8135%，RMSE 在 1.9303%，同比于 GRU 模型误差降低了 23.0496%。为了验证本文在不同温度下 EMD-GRU 模型的有效性，表 6 所示为 EMD-GRU 模型锂离子电池不同温度下 SOC 估计误差，可以看出所有温度条件下的 MAE 在 1.7% 以内，满足 SOC 估计的需求。

表6 EMD-GRU模型锂离子电池不同温度下SOC估计误差
Tab.6 EMD-GRU model lithium-ion battery SOC estimation error at different temperatures

温度	MAE(%)	MSE(%)	RMSE(%)
10℃	1.5461	0.0400	2.0008
20℃	1.2983	0.0281	1.6759
30℃	1.6172	0.0422	2.0548
40℃	1.5756	0.0396	1.9896
平均	1.5093	0.0375	1.9303

图 10 为 EMD-GRU 模型锂离子电池不同温度 SOC 估计结果，可以得到不同时刻的 SOC 估计情况，当 SOC 在 50% 时候，图形的斜率变缓了，导致误差增加，经过分析得出 10℃ 温度下这部分误差主要原因是因为训练数据和测试数据之间差异较大。训练数据的放电电流时间积分与充电电流时间积分的差值要大于测试数据，当满足训练数据的模型参数应用于测试数据导致在中间部分下降较为缓慢，符合实际理论的。




图 10 EMD-GRU 模型锂离子电池不同温度 SOC 估计结果

Fig.10 EMD-GRU model lithium-ion battery SOC estimation results at different temperatures

5 结论

本文介绍了循环神经网络算法优缺点，进而引

入一种循环神经网络的变种 GRU。为了提高 GRU 模型锂离子电池 SOC 估计精度，提出用 EMD 算法分解电流，将电流分为若干个电流子序列，加上电压和温度信号作为 GRU 网络输入，SOC 值作为 GRU 网络输出训练网络参数，提高了 SOC 的估计精度。在不同温度和不同工况下仿真分析得出，GRU 网络的锂离子电池 SOC 估计精度优于 RNN 和 LSTM，所提 EMD-GRU 在 SOC 估计中，MAE 在 1.5093%，MSE 在 0.0375%，RMSE 在 1.9303%，验证了本文方法的有效性。

本文方法是在不同温度下进行 SOC 估计，在实际应用场景中，电池的温度是动态变化的，因此缺乏变系统温度和老化适应性的讨论，其次测量电流信号分解过程是经验过程，不易于快速估计电池的 SOC。

参考文献

- [1] 温法政. 锂离子电池高精度建模与多状态智能估计[D]. 山东大学, 2020.
- [2] 孙国强, 任佳琦, 成乐祥, 等. 基于分数阶阻抗模型的磷酸铁锂电池荷电状态估计[J]. 电力系统自动化, 2018, 42(23):57-63.
- [3] 费亚龙, 谢长君, 汤泽波, 曾春年, 全书海. 基于平方根无迹卡尔曼滤波的锂电池状态估计[J]. 中国电机工程学报, 2017, 37(15):4514-4520+4593.
- [4] Chen L, Wang Z, Z L, et al. A Novel State-of-Charge Estimation Method of Lithium-Ion Batteries Combining the Grey Model and Genetic Algorithms[J]. IEEE Transactions on Power Electronics, 2018, 33(10): 8797-8807.
- [5] Meng J, Stroe D, Ricco M, et al. A Simplified Model-Based State-of-Charge Estimation Approach for Lithium-Ion Battery With Dynamic Linear Model[J]. IEEE Transactions on Industrial Electronics, 2019, 66(10): 7717-7727.
- [6] 杨亚丽, 李匡成, 陈涛, 袁文涛, 刘瑾. 采用电动势-内阻模型在线估计蓄电池荷电状态[J]. 电测与仪表, 2010, 47(03):16-19+37.
- [7] 高明煜, 何志伟, 徐杰. 基于采样点卡尔曼滤波的动力电池 SOC 估计 [J]. 电工技术学报, 2011, 26(11):161-167.
- [8] 谢长君, 费亚龙, 曾春年, 房伟. 基于无迹粒子滤波的车载锂离子电池状态估计[J]. 电工技术学报, 2018, 33(17):3958-3964.

- [9] 魏克新,陈峭岩.基于自适应无迹卡尔曼滤波算法的锂离子动力电池状态估计[J].中国电机工程学报,2014,34(03):445-452.
- [10] Ragone M, Yurkiv V, Ramasubramanian A, et al. Data driven estimation of electric vehicle battery state-of-charge informed by automotive simulations and multi-physics modeling[J]. Journal of Power Sources, 2021, 483: 229108.
- [11] 刘兴涛,李坤,武骥,何耀,刘新天.基于EKF-SVM算法的动力电池SOC估计[J].汽车工程,2020,42(11):1522-1528+1544.
- [12] 孔祥创,赵万忠,王春燕.基于BP-EKF算法的锂电池SOC联合估计[J].汽车工程,2017,39(06):648-652.
- [13] Hu X, Li S, Peng H, et al. Robustness analysis of State-of-Charge estimation methods for two types of Li-ion batteries[J]. Journal of Power Sources, 2012, 217: 209-219.
- [14] Tian Y, Lai R, Li X, et al. A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter[J]. Applied Energy, 2020, 265: 114789.
- [15] Yang F, Zhang S, Li W, et al. State-of-charge estimation of lithium-ion batteries using LSTM and UKF[J]. Energy, 2020, 201: 117664.
- [16] Yang F, Li W, Li C, et al. State-of-charge estimation of lithium-ion batteries based on gated recurrent neural network[J]. Energy, 2019, 175: 66-75.
- [17] 李超然,肖飞,樊亚翔,杨国润,唐欣.基于门控循环单元神经网络和Huber-M估计鲁棒卡尔曼滤波融合方法的锂离子电池荷电状态估算方法[J].电工技术学报,2020,35(09):2051-2062.
- [18] 李超然,肖飞,樊亚翔,唐欣,杨国润.基于深度学习的锂离子电池SOC和SOH联合估算[J].中国电机工程学报,2021,41(02):681-692.
- [19] 刘昊天,王萍,程泽.一种编解码器模型的锂离子电池健康状态估算[J].中国电机工程学报,2021,41(05):1851-1860.
- [20] 金秀章,刘岳,于静,王建峰,郝英杰.基于变量选择和EMD-LSTM网络的出口SO₂浓度预测[J/OL].中国电机工程学报:1-10[2021-04-30].
<http://kns.cnki.net/kcms/detail/11.2107.TM.20210416.1541.009.html>.
- [21] Pecht M. Battery Data Set. CALCE, CALCE Battery Research Group, Maryland, MD; 2017. Available: <https://web.calce.umd.edu/batteries/data.htm>.
-
- 作者简介
李宁 男, 1983年生, 博士, 副教授, 研究方向为的电力电子化的电力系统及其控制。
E-mail: lining83@xaut.edu.cn (通信作者)
何复兴 男, 1995年生, 硕士研究生, 研究方向为锂离子电池SOC估计。
E-mail: 1216484943@qq.com