

DOI:10.19651/j.cnki.emt.2211098

基于改进 GRU 模型算法的锂电池 SOC 估计*

张心成 李翔晟 李藏龙 曾 军 秦 祥

(中南林业科技大学机电工程学院 长沙 410004)

摘要: 锂电池荷电状态(SOC)的准确估计对提高电池的动态性能和能量利用率至关重要。针对现有神经网络 SOC 估计方法在复杂工况下存在精度低,稳定性差等问题,本文提出一种改进 GRU 模型算法对 SOC 进行估计。首先将 1DCNN 和 Bi-GRU 相结合并添加注意力机制,构建 1DCNN-Bi-GRU-ATT 模型。其次,为解决 ReLU 激活函数易出现死神经元现象,将其改进为 PReLU 激活函数。同时,为解决 MSE-Loss 易受复杂工况中电池异常数据影响和 MAE-Loss 收敛速度较慢等问题,改用 Huber-Loss 作为网络损失函数。最后,将 Adam 算法使用 Nesterov 加速梯度改进为 Nadam 算法。锂电池 SOC 估计实验结果表明,在 12 种复杂工况下该模型算法的均方根误差和平均绝对误差的平均值分别为 1.181 7% 和 0.924 1%,与改进前及其他模型相比,本文模型在 12 种情况中综合表现更为稳定和准确,有更高的泛化性。

关键词: 锂电池;荷电状态;注意力机制;GRU;PReLU;Huber-Loss;Nadam

中图分类号: TM921 **文献标识码:** A **国家标准学科分类代码:** 460

SOC estimation of lithium battery based on improved gated recurrent Unit model algorithm

Zhang Xincheng Li Xiangsheng Li Canglong Zeng Jun Qin Xiang

(School of Mechanical and Electrical Engineering, Central South University of Forestry and Technology, Changsha 410004, China)

Abstract: Accurate estimation of the state of charge (SOC) of lithium batteries is crucial to improving the dynamic performance and energy utilization of batteries. Aiming at the problems of low accuracy and poor stability of existing neural network SOC estimation methods under complex working conditions, this paper proposes an improved GRU model algorithm to estimate SOC. Firstly, combine 1DCNN and Bi-GRU and add attention mechanism to build 1DCNN-Bi-GRU-ATT model. Secondly, in order to eliminate the phenomenon that the ReLU activation function is prone to dead neurons, it is improved to PReLU activation function. At the same time, in order to solve the problem that MSE-Loss is easily affected by abnormal battery data in complex working conditions and the convergence speed of MAE-Loss is slow, Huber-Loss is used instead as the network loss function. Finally, the Adam algorithm is improved to Nadam algorithm using Nesterov accelerated gradient. The experimental results of lithium battery SOC estimation show that the average values of root mean square error and mean absolute error of the model algorithm under 12 complex operating conditions are 1.181 7% and 0.924 1%, respectively. Compared with the model before improvement and other models, the comprehensive performance of this model in 12 cases is more stable and accurate, and it has higher generalizability.

Keywords: lithium battery; SOC; attention mechanism; gated recurrent unit; PReLU; Huber-Loss; Nadam

0 引 言

锂电池作为储能元件,具有寿命长、能量密度高等优点,被广泛运用于各类电动汽车。锂电池荷电状态(state of charge, SOC)定义为电池剩余容量与总容量的比值,是

电池管理系统(battery management system, BMS)需要监测的重要状态之一^[1],通过锂电池 SOC 准确估计可有效避免电池产生过充过放现象,以确保电池在安全范围内运行,进而提高电池的使用寿命。因此,锂电池 SOC 准确估计对提高电动汽车电池利用率、优化电动汽车性能意义重大。

收稿日期:2022-08-17

* 基金项目:湖南省自然科学基金省市联合项目(14JJ5014)、中南林业科技大学研究生科技创新基金(CX202102039)项目资助

但在实际的车载电池放电过程中工况复杂多变, 锂电池 SOC 准确估计仍存在挑战。

目前电池 SOC 估计方法主要有安时积分法、开路电压法、卡尔曼滤波法和神经网络法等。但安时积分法需提前获得初始 SOC, 且存在累计误差^[2-3]; 开路电压法需要静置较长的时间, 不适合在线测量^[4]; 内阻测量法需要精确测量仪器^[5]; 卡尔曼滤波方法^[6-7] 依赖建立精确的电池数学模型, 然而精确构建电池数学模型本身就具有高度的挑战性。神经网络方法则无需对电池复杂的内部结构和电化学与物理层面的动态特性进行分析和建模, 只需建立深度学习模型, 使用电压、电流、温度等影响电池 SOC 估计相关的数据, 对其进行训练并预测即可获得所估计 SOC 值, 且精度较高, 近年来已成为研究热点。李超然等^[8] 使用循环神经网络(recurrent neural network, RNN) 估计 SOC, 取得良好效果, 但 RNN 自身存在造成梯度消失和梯度爆炸的缺陷; 郑永飞等^[9] 使用长短期记忆网络(long short-term memory, LSTM) 估计 SOC, 解决了 RNN 存在的梯度消失和梯度爆炸等问题, 但 LSTM 对复杂工况数据的学习能力有限; 倪水平等^[10] 使用一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN) 结合 LSTM, 通过提取数据特征, 进一步提升了 SOC 的估计精度, 但卷积层采用的 ReLU 激活函数容易出现死神经元从而导致梯度消失。以上等人采用的 Adam 优化算法在 0 梯度附近容易过冲, 且采用 MSE 损失函数导致模型对异常数据的抗干扰能力弱, 模型仅满足恒定温度恒流放电工况的 SOC 估计需求, 在不同温度的多种复杂工况下模型精度较低, 稳定性较差, 难以满足在多种复杂工况下对 SOC 准确估计的需求。

为了提高锂电池在复杂工况下 SOC 的估计精度和稳定性, 本文基于前人的研究, 以门控循环单元(gated recurrent unit, GRU) 为基础, 在前端嵌入一维卷积层, 以提取电压、电流、温度等输入数据的高级特征, 并使用双向 GRU, 再对其增添注意力机制(attention mechanism, ATT), 构建 1DCNN-Bi-GRU-ATT 模型。其次, 改用 PReLU 激活函数, 以解决常用的 ReLU 激活函数易出现死神经元问题, 同时, 改用 Huber-Loss 作为损失函数, 以解决 MSE-Loss 易受复杂工况中电池异常数据影响和 MAE-Loss 收敛速度较慢等问题。最后, 将 Adam 算法改进为 Nadam 算法, 进一步提升整体模型算法在多种复杂工况下的 SOC 估计精度和稳定性。

1 GRU 简介

GRU 是基于 LSTM 的改进模型, 将 LSTM 中的输入门和遗忘门合并成更新门, 用来控制前一时间刻和当前时刻的信息向后传递的数量, 重置门控制信息遗忘的程度。GRU 既能实现和 LSTM 同样的功能, 有效处理梯度消失和梯度爆炸等问题, 而且网络结构更为简洁, 训练的参数更少, 在处理更低维度的数据集上更具优势。GRU 网络结构

如图 1 所示。




图 1 GRU 结构

2 模型改进

2.1 模型结构的改进

本文对 GRU 结构进行改进, 将其命名为 1DCNN-Bi-GRU-ATT, 结构如图 2 所示。

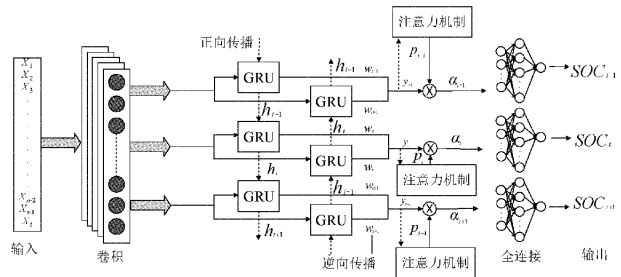


图 2 本文模型结构

首先, 针对于电池输入数据电压、电流、温度这类时间序列数据使用一维卷积层^[11]来提取输入数据的高级特征。此外本文 SOC 数据维度不高, 不设置池化层进行下采样。由于 ReLU 激活函数有收敛快的优点, 卷积层常选用 ReLU 激活函数, ReLU 激活函数表达式如式(1)所示, 图像如图 3 所示。但 ReLU 也有缺点, 其输入为负值时其输出均为 0, 而当反向传播时, 若某次权重参数变为负数时, 会导致这个神经元自身参数的梯度恒为 0, 在以后的训练过程中永远不能被激活, 出现“死神经元”的现象, 从而引起梯度消失, 为解决这一问题, 许多学者将其改进的为 PReLU^[12], 表达式如式(2)所示, 图像如图 4 所示。

$$f(x) = \max(0, x) \tag{1}$$

$$f(x) = \max(ax, x) \tag{2}$$

其中, a 的值一般为很小的值, 改进后的 PReLU 激活函数既解决了梯度消失问题, 又保留了原始 ReLU 计算量小, 速度快的优点, 因此, 本文针对于卷积层, 将其激活函数 ReLU 改用为 PReLU。

在 SOC 实际估计中, GRU 从时间维度仅用过去的历史数据单向考虑电池的监测数据与相应 SOC 之间的相关程度, 可能无法充分捕捉暗藏的电池物理和电化学的动态特征, 因此, 将 GRU 由单向改进为双向, 即 Bi-GRU, 其目的是利用待估计的 SOC 值相关时刻前后的电池数据来进行估计, 以此来提高复杂工况下对 SOC 估计的精度。模型 Bi-GRU 部分结构如图 5 所示。




图 3 ReLU




图 4 PReLU

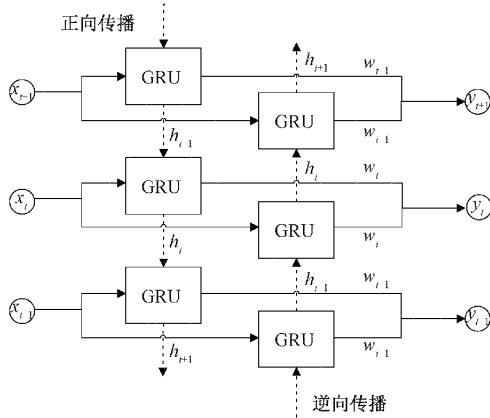


图 5 Bi-GRU 结构

Bi-GRU 每个当前时刻输出 y_t 都由 3 部分决定:沿时间轴正向传播的前一时刻隐藏层输出状态 h_{t-1} 、沿时间轴逆向传播的前一时刻的隐藏层输出状态 h_{t+1} 、当前时刻的输入 x_t 。

最后,对 Bi-GRU 输出的隐藏层状态,加上注意力机制^[13]。注意力机制是模拟人脑对信息的关注,忽略没那么重要或者无效的信息,集中注意力关注有效信息。Bi-GRU 结构虽然可以从双向的时间维度挖掘数据信息,但存在信息过载问题,即输入数据中,不同时刻的放电数据对当前 SOC 的影响程度并不一致,注意力机制可以解决这个问题,对不同时刻的数据加以不同的权重来考虑,使模型优先关注到对当前 SOC 影响较大时刻的放电数据,提高有效或高效数据的权重,其作用过程由式(3)~(5)表示:

$$\text{score}([\mathbf{h}_{t,i}, \mathbf{y}_t]) = \omega_t \mathbf{y}_t^T + b_t \quad (3)$$

$$p_t = \frac{\exp(\text{score}([\mathbf{h}_{t,i}, \mathbf{y}_t]))}{\sum_{i=1}^m \exp(\text{score}([\mathbf{h}_{t,i}, \mathbf{y}_t]))} \quad (4)$$

$$\alpha_t = \sum_{i=1}^m p_t \mathbf{y}_t \quad (5)$$

其中, \mathbf{y}_t 为 Attention 结构的输入,即前述 Bi-GRU 结构的输出的隐藏状态; $\text{score}([\mathbf{h}_{t,i}, \mathbf{y}_t])$ 为对 t 时刻的隐藏层状态 \mathbf{y}_t 与放电数据的特征向量 $\mathbf{h}_{t,i}$ 的相关性分数,由输入数据转置后与权值矩阵和偏差向量计算所得; \mathbf{p}_t 为使用 softmax 激活函数得到的概率向量,即数据的注意力权重; α_t 为 Attention 结构的输出,即输入数据的加权平均值,将其输入到全连接层即可输出要估计 SOC 值。

2.2 损失函数的改进

在大多数回归预测任务里,GRU 网络一般采用均方误差(mean square error, MSE)或平均绝对误差(mean absolute error, MAE)作为的回归损失函数,其计算公式如下:

$$\text{MSE} = \frac{1}{m} \sum_{k=1}^m (\tilde{y}_k - y_k)^2 \quad (6)$$

$$\text{MAE} = \frac{1}{m} \sum_{k=1}^m |\tilde{y}_k - y_k| \quad (7)$$

其中, y_k 和 \tilde{y}_k 分别表示在 k 时刻的 SOC 真实值与估计值。

由 MAE 公式可看出,MAE 对异常值具有较好的鲁棒性,如果对所有样本点只给出一个预测值,那么这个值就是所有目标值的中位数,但其缺点是它的损失梯度始终不变,不利于模型收敛,而 MSE 的损失梯度随着损失增大而增大,而损失趋近于 0 时则会减小,这使得在训练结束时,使用 MSE 模型的结果会比 MAE 更精确,但由于其对误差取了平方,会赋予异常值更大的权重,但却是以牺牲其他正常数据点的预测效果为代价,因此会导致降低模型的整体性能。

针对上述问题,本文改用 Huber Loss^[14]作为网络回归损失函数,其公式如下:

$$\text{Huber_Loss}_\delta = \begin{cases} \frac{1}{2} \sum_{k=1}^m (\tilde{y}_k - y_k)^2, & |\tilde{y}_k - y_k| \leq \delta \\ \delta \sum_{k=1}^m |\tilde{y}_k - y_k| - \frac{1}{2} \delta^2, & \text{其他} \end{cases} \quad (8)$$

式中: δ 为超参数,它决定了模型愿意考虑的异常值,Huber 本质为分段函数,当其损失在 $[0 - \delta, 0 + \delta]$ 之间时,为 MSE,而在 $[-\infty, \delta]$ 和 $[\delta, +\infty]$ 时相当于 MAE。因此,Huber Loss 损失函数同时具备 MAE 和 MSE 的优点。

2.3 优化器算法的改进

Adam^[15]算法在具有稀疏性的数据中表现最好,优点是权重参数更新快,从而加速收敛,其本质是 RMSprop 加上经典动量 Momentum,但经典动量 Momentum 有一个问题:当梯度为 0 或在 0 附近时,仍旧会以较大的幅度更新参

数,即过冲。

针对上述问题,本文改用带有 Nesterov 的加速梯度(Nesterov accelerating gradient, NAG) 的 Adam 优化器,即 Nadam。NAG 是经典动量 Momentum 的拓展,相当于给经典动量 Momentum 加了矫正因子,Adam 算法和 Nadam 算法的更新公式如表 1 所示。

表 1 算法对比

改进前 Adam 算法	改进后 Nadam 算法
$g_t \leftarrow \nabla_{\theta_{t-1}} f(\theta_{t-1})$	$g_t \leftarrow \nabla_{\theta_{t-1}} f(\theta_{t-1})$
$m_t \leftarrow \mu m_{t-1} + (1-\mu)g_t$	$\hat{g}_t \leftarrow \frac{g_t}{1 - \prod_{i=1}^t \mu_i}$
$\hat{m}_t \leftarrow \frac{m_t}{1-\mu^t}$	$m_t \leftarrow \mu m_{t-1} + (1-\mu)\hat{g}_t$
$n_t \leftarrow \nu n_{t-1} + (1-\nu)g_t^2$	$\hat{m}_t \leftarrow \frac{m_t}{1 - \prod_{i=1}^t \mu_i}$
$\hat{n}_t \leftarrow \frac{n_t}{1-\nu^t}$	$n_t \leftarrow \nu n_{t-1} + (1-\nu)g_t^2$
$\theta_t \leftarrow \theta_{t-1} - \eta \frac{\hat{m}_t}{\sqrt{\hat{n}_t} + \epsilon}$	$\hat{n}_t \leftarrow \frac{n_t}{1-\nu^t}$
	$\bar{m}_t \leftarrow (1-\mu_t)\hat{g}_t + \mu_{t+1}\hat{m}_t$
	$\theta_t \leftarrow \theta_{t-1} - \eta \frac{\bar{m}_t}{\sqrt{\hat{n}_t} + \epsilon}$

式中: g_t 为 t 时刻的梯度, m_t 和 n_t 分别为一阶矩预测即 Momentum 项和二阶矩预测即 RMSProp 项, \hat{m}_t 和 \hat{n}_t 分别为对 m_t 和 n_t 的修正, \bar{m}_t 为加入 Nesterov 技巧后改写的一阶矩预测的修正向量, θ_t 为所需更新损失函数里的参数, η 学习率默认为 0.001, 指数衰减率 μ 和 ν 分别默认为 0.9 和 0.999, 常量 ϵ 默认为 10^{-8} 。由公式可以看出, Nadam 对学习率有了更强的约束, 同时对梯度的更新也有更直接的影响, Sebastian Ruder^[16] 表明 Nesterov 的加速梯度(NAG) 在大多数情况中表现比 Adam 好, 因此, 本文将 Adam 中的经典动量改为 NAG, 改用 Nadam 算法。

3 实验和数据预处理

3.1 实验数据及评价指标

本文实验采用加拿大马克马斯特大学自动化所的 Panasonic 18650PF 锂电池数据集^[17], 选取该数据集中 Cycle_1、Cycle_2、Cycle_3、Cycle_4 及 NN 工况作为训练集, UDDS、HWFET、US06 及 LA92 工况作为测试集, 选取端电压、电流、电池温度作为模型输入, SOC 作为模型输出, SOC 值由放电量按定义式计算所得。

为更好地对模型进行评价, 选用使用均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)作为验证模型优劣的评价指标。其计算公式分别如式(9)、(10)所示。

$$RMSE = \sqrt{\frac{1}{m} \sum_{k=1}^m (\bar{y}_k - y_k)^2} \tag{9}$$

$$MAE = \frac{1}{m} \sum_{k=1}^m |\bar{y}_k - y_k| \tag{10}$$

其中, y_k 和 \bar{y}_k 分别表示在 k 时刻的 SOC 真实值与估计值。

3.2 实验环境设置及数据预处理

本文采用 TensorFlow2.0 深度学习框架, Python 编程语言, Windows10 操作系统和 GeForce GTX 1650 显卡。具体实验配置如表 2 所示。

表 2 实验环境配置

参数	配置
GPU	GeForce GTX 1650
语言	Python3.7
系统环境	Windows10
加速环境	CUDA10.0

为避免模型复杂而导致模型过拟合, 加快训练速度且有效的提高 1DCNN-Bi-GRU-ATT 模型预测精度与稳定性, 应适当地设置神经元节点数、时间步长、批处理大小、迭代次数、隐藏层层数和学习率。经共计 44 组超参数对比寻优实验, 本文模型参数最终设置如下, 一层具有 30 个滤波器, 卷积核大小为 3, 卷积步长为 1 的 1DCNN 层; 一层具有 10 个神经元节点的 Bi-GRU 层; 一层具有 1 个节点的全连接层作为输出层; 模型的时间步长设置为 50; 模型最大迭代次数设置为 60; 模型批处理大小设置为 256; 学习率设置为 0.001; 层间 dropout 为 0.2。训练结束后, 利用测试集对训练好的模型进行测试, 得出预测误差和结果。

本文 SOC 预测模型属于多输入单输出的模型, 需要将标准化后的数据进行窗口化处理, 使模型的每个输入样本包含多个历史时刻的数据, 如图 6 所示, 图中窗口长度为 n , 即为时间步长这一参数。窗口大小表征了每个样本数据的数据量, 即使用窗口范围内的数据 X_t 对 Y_t 进行预测, 滑动一个数据, 变为使用 X_{t-1} 对 Y_{t-1} 进行预测。




图 6 数据窗口化

最终, 本文模型训练和预测过程如图 7 所示。

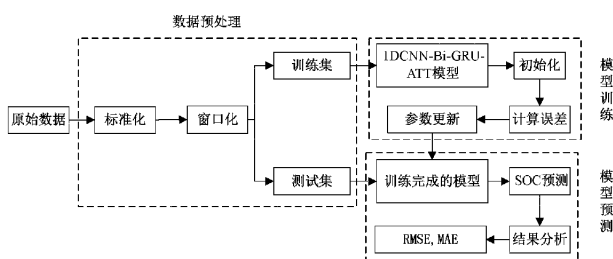


图 7 训练和预测框架图

4 实验结果对比分析

由表 3 可知,原 GRU 模型算法,与本文改进后模型算法,在不同工况和不同温度中,对 SOC 的估计能力,均表现不同,不难发现,在同一工况中随着温度的下降, RMSE 和 MAE 均有波动。在 UDDS 工况中,本文模型算法在 25 °C 时 RMSE 和 MAE 极小,远小于同工况的 GRU 模型算法的 RMSE 和 MAE,虽易受温度影响,但在 UDDS 工况中本文模型总体仍好于 GRU 模型。在 HWFET 工况中,改进前后模型,3 种温度的 RMSE 和 MAE 均表现较为稳定,波动较小,但本文模型算法的 RMSE 和 MAE 总体均远小于 GRU 算法的 RMSE 和 MAE。在 US06 工况中,GRU 模型对 SOC 的估计表现最不稳定,25 °C 时 RMSE 高达 3.565 2%, MAE 也高达 2.304 0%, RMSE 与 MAE 最大差值出现在 25 °C 与 0 °C 之间,分别为 1.548 4% 和 0.709 9%,而改进后模型算法在 US06 工况中, RMSE 与 MAE 在 25 °C 与 0 °C 时的差值仅分别为 0.160 2% 和 0.303 8%,改进后的模型算法与原 GRU 相比,对抗温度干扰能力更强。在 LA92 工况中,改进前后模型的 RMSE 和 MAE 均随温度而增加,但改进后本文模型总体好于原 GRU。在 12 种工况中,本

表 3 GRU 改进前后在不同测试集上的评估

工况	温度/ °C	本文模型算法		GRU	
		RMSE/ %	MAE/ %	RMSE/ %	MAE/ %
UDDS	25	0.446 1	0.342 9	1.078 4	0.814 5
	10	1.412 4	1.135 1	1.578 5	1.200 6
	0	1.132 8	0.798 4	1.379 1	0.982 3
HWFET	25	1.241 9	0.965 4	2.257 5	1.952 1
	10	1.755 7	1.380 8	2.581 9	2.274 2
	0	1.670 4	1.489 1	2.440 7	2.239 1
US06	25	1.211 9	0.805 3	3.565 2	2.304 0
	10	1.667 4	1.279 0	2.191 1	1.587 2
	0	1.372 1	1.109 1	2.016 7	1.594 1
LA92	25	0.473 6	0.351 7	0.905 9	0.688 7
	10	0.769 6	0.599 7	1.312 7	0.998 9
	0	1.026 5	0.832 4	1.814 1	1.448 8
平均		1.181 7	0.924 1	1.926 8	1.507 0

文模型对 SOC 的估计值,不仅在 RMSE 和 MAE 上均取得最小值,而且平均 RMSE 为 1.181 7%,平均 MAE 为 0.924 1%,在复杂工况下对 SOC 的估计精度更高更稳定。

由表 4 可知,本文改进后模型算法,随着优化策略的逐步增加,在 12 种工况中对 SOC 的估计的平均 RMSE 与平均 MAE 逐步降低,验证了各优化策略均起到一定程度的效用。

表 4 不同模型在测试集上的评估

实验	改进结构	Huber Loss	Nadam 算法	RPeLU	RMSE/ %	MAE/ %
1					1.926 8	1.507 0
2	✓				1.352 3	1.109 1
3	✓	✓			1.249 5	0.985 2
4	✓	✓	✓		1.247 2	0.964 5
5	✓	✓	✓	✓	1.181 7	0.924 1

图 8~19 分别为 4 种工况对应 3 种温度的测试结果,其中,图 8(a)~19(a)为改进前后估计结果对比,图 8(b)~19(b)为改进前后估计误差对比,从中可看出,改进前后的模型算法 SOC 估计的走势均符合实际趋势,但本文模型算法在 12 种情况下对 SOC 估计更接近实际 SOC,的总体表现更为优秀,误差曲线与原 GRU 相比对波动更小。此外,不难发现,原 GRU 模型算法对 SOC 的估计,在初始和末尾

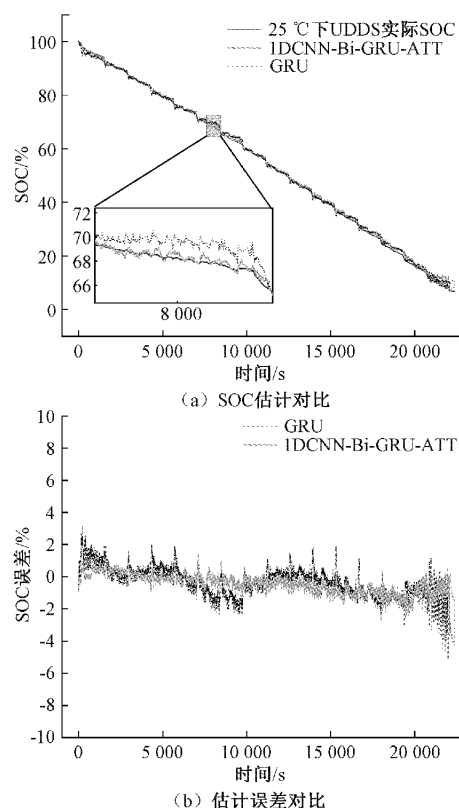
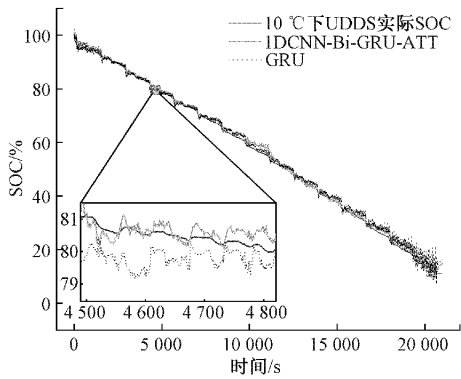



图 8 改进前后在 25 °C UDDS 工况下对比图

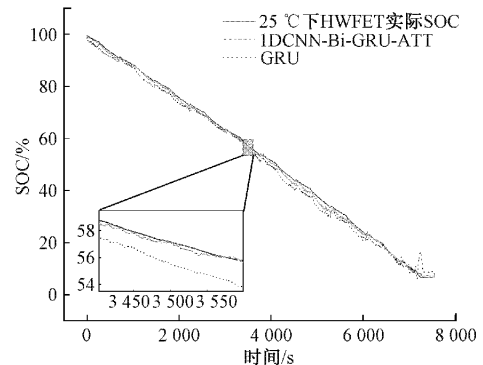


(a) SOC 估计对比




(b) 估计误差对比

图 9 改进前后在 10 °C UDDS 工况下对比图




(a) SOC 估计对比




(b) 估计误差对比

图 11 改进前后在 25 °C HWFET 工况下对比图




(a) SOC 估计对比

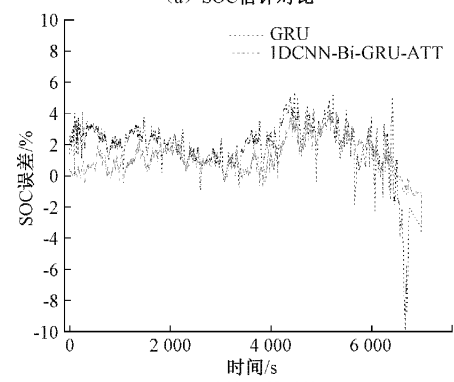


(b) 估计误差对比

图 10 改进前后在 0 °C UDDS 工况下对比图

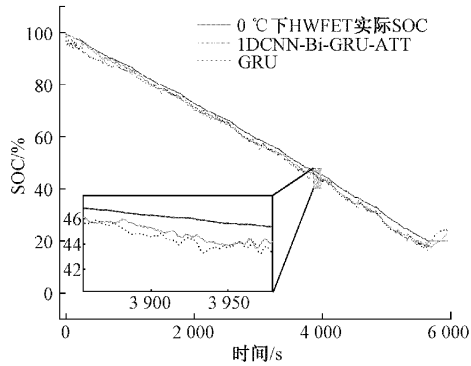


(a) SOC 估计对比




(b) 估计误差对比

图 12 改进前后在 10 °C HWFET 工况下对比图

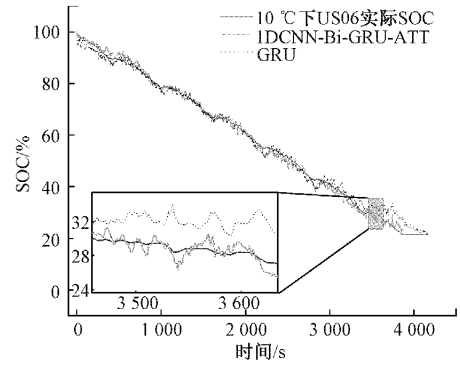


(a) SOC估计对比




(b) 估计误差对比

图13 改进前后在0°C HWFET工况下对比图




(a) SOC估计对比




(b) 估计误差对比

图15 改进前后在10°C US06工况下对比图

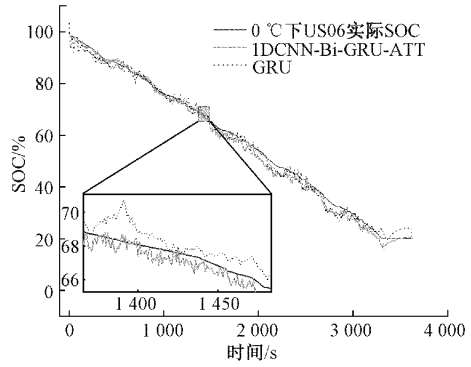


(a) SOC估计对比




(b) 估计误差对比

图14 改进前后在25°C US06工况下对比图



(a) SOC估计对比




(b) 估计误差对比

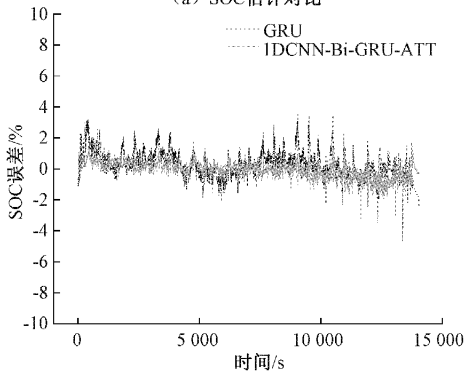
图16 改进前后在0°C US06工况下对比图

时往往估计误差波动较大,这是由于电池放电初始和结束时电压变化幅度较大,也存在一定监测误差,模型将其视为

异常数据,本文改进模型算法在电池放电初始和结束时与之相比误差波动较为平稳,由此可见,本文改进模型对异常




(a) SOC 估计对比




(b) 估计误差对比

图 17 改进前后在 25 °C LA92 工况下对比图

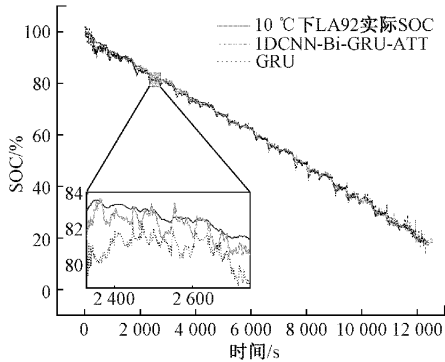


(a) SOC 估计对比




(b) 估计误差对比

图 19 改进前后在 0 °C LA92 工况下对比图



(a) SOC 估计对比



(b) 估计误差对比

图 18 改进前后在 10 °C LA92 工况下对比图

数据的鲁棒性更强,在各种温度复杂工况中对 SOC 估计更为精准,受异常数据的影响更小。

表 5 为相同条件下,本文模型算法与 LSTM、CNN-LSTM、Bi-LSTM 和 Bi-GRU,在 12 种工况下对 SOC 估计的平均 RMSE 与平均 MAE,从表中数据可知,本文改进的模型算法,在各种复杂工况下对 SOC 估计综合表现最优,泛化性最强。

表 5 不同算法 SOC 预测结果对比

模型	RMSE/%	MAE/%
LSTM ^[9]	1.898 2	1.540 0
CNN-LSTM ^[10]	1.801 9	1.469 1
Bi-LSTM ^[17]	1.710 7	1.368 7
Bi-GRU ^[17]	1.846 8	1.377 2
本文模型算法	1.181 7	0.924 1

5 结 论

本文提出一种改进的 GRU 算法以解决复杂工况下电池 SOC 难以准确估计的问题。通过构建 1DCNN-Bi-GRU-ATT 模型,优化卷积层激活函数,替换回归损失函数,改用经 NAG 加速的 Adam 优化算法即 Nadam 优化算法,提高模型在复杂工况下的 SOC 估计精度,实验结果表明,本文优化模型算法在不同温度不同工况共计 12 种情况中平均 RMSE 为 1.181 7%、平均 MAE 为 0.924 1%,在相同实验条件下,本文模型算法与原 GRU、LSTM、Bi-LSTM、

Bi-GRU、CNN-LSTM 模型算法相比,估计精度和稳定性均有大幅度提升,综合表现最优,为后续的锂电池在复杂工况下的 SOC 精确估计提供了新思路,具有一定的研究意义。

参考文献

- [1] 桂阳,周飞,杨文,等. 基于双向 GRU 和 H_{∞} 滤波器的 SOC 复合估算[J]. 电源技术,2022,46(4):384-389.
- [2] 刘伟龙,王丽芳,廖承林,等. 基于模型融合与自适应无迹卡尔曼滤波算法的锂离子电池 SOC 估计[J]. 汽车工程,2017,39(9):997-1003.
- [3] 周韦润,姜文刚. 基于遗传算法优化扩展卡尔曼滤波的锂电池 SOC 估计[J]. 重庆理工大学学报(自然科学),2019,33(9):33-39.
- [4] WANG Q Q, WANG J, ZHAO P J, et al. Correlation between the model accuracy and model-based SOC estimation [J]. *Electrochimica Acta*, 2017, 228: 146-159.
- [5] MA Y, LI X, LI G, et al. SOC oriented electrochemical-thermal coupled modeling for lithium-ion battery[J]. *IEEE Access*,2019,7:156136-156149.
- [6] 郝世宇,殷会飞,杨茹,等. 基于 AEKF 的锂离子动力电池荷电状态估计[J]. 国外电子测量技术,2021,40(9):49-53.
- [7] 张利,朱雅俊,刘征宇. 锂离子电池 SOC 与模型参数联合估算研究[J]. 电子测量与仪器学报,2012,26(4):320-324.
- [8] 李超然,肖飞,樊亚翔. 基于循环神经网络的锂电池 SOC 估算方法[J]. 海军工程大学学报,2019,31(6):107-112.
- [9] 郑永飞,文怀兴,韩昉,等. 基于 LSTM 神经网络的动力电池 SOC 估算研究[J]. 计算机应用与软件,2020,37(3):78-81,88.
- [10] 倪水平,李慧芳. 基于一维卷积神经网络与长短期记忆网络结合的电池荷电状态预测方法[J]. 计算机应用,2021,41(5):1514-1521.
- [11] SONG X, YANG F, WANG D, et al. Combined CNN-LSTM network for state-of-charge estimation of lithium-ion batteries[J]. *IEEE Access*, 2019,7: 88894-88902, DOI: org/10.1109/ACCESS.2019.2926517.
- [12] 刘小文,郭大波,李聪. 卷积神经网络中激活函数的一种改进[J]. 测试技术学报,2019,33(2):121-125.
- [13] 陈海涵,吴国栋,李景霞,等. 基于注意力机制的深度学习推荐研究进展[J]. 计算机工程与科学,2021,43(2):370-380.
- [14] 冯林娅,姚力,赵小杰. 引入 Huber 损失函数的睡眠脑电数据增强模型研究[J]. 北京师范大学学报(自然科学版),2021,57(6):875-882.
- [15] YADAV R K, ANUBHAV. PSO-GA based hybrid with adam optimization for ANN training with application in medical diagnosis[J]. *Cognitive Systems Research*,2020,64:191-199.
- [16] RUDER S. An overview of gradient descent optimization algorithms [J]. *ArXiv Preprint*, 2016, ArXiv:1609.04747.
- [17] 朱元富,贺文武,李建兴,等. 基于 Bi-LSTM/Bi-GRU 循环神经网络的锂电池 SOC 估计[J]. 储能科学与技术,2021,10(3):1163-1176.

作者简介

张心成,硕士研究生,主要研究方向为锂电池荷电状态估计、深度学习等。

E-mail:675817729@qq.com

李翔晟(通信作者),博士,教授,主要研究方向为机电液一体化及控制、新能源汽车技术等。

E-mail:jerry@126.com