

基于Informer的电池荷电状态估算及其 稀疏优化方法

何滢婕, 刘月峰, 边浩东, 郭 威, 张小燕

(内蒙古科技大学信息工程学院, 内蒙古包头 014010)

摘要: 准确估计电池荷电状态(State Of Charge, SOC)是延长电动汽车电池使用寿命, 确保电动汽车行驶安全的重要基础. 传统的深度学习估计方法存在并行化计算效率不高、训练时间长的问題. 为此, 利用基于自注意力机制的Informer模型来估计电池SOC. 其降低了传统自注意力机制的时间复杂度、提高了硬件使用率、降低了训练时长, 与其他深度学习方法相比估计更准确. 然而Informer模型仍然存在体量大及参数冗余的问题, 故提出稀疏优化方法. 利用基于彩票假设的幅值迭代剪枝方法对Informer进行稀疏化处理, 突出主导注意力特征, 实现了在降低参数冗余的同时提升模型估计精度. 在室温下, 提出的稀疏化Informer模型估计电池SOC的平均绝对误差和均方根误差分别达到0.285 8%和0.383 0%, 相比于Informer模型在平均绝对误差指标上估计精度提升了25%. 并验证了其具备估计不同类型锂电池SOC的泛化能力. 与循环神经网络、卷积神经网络这类传统的深度学习模型相比, 本模型进行电池SOC估计时训练速度更快, 估计准确性和稳定性更高.

关键词: 荷电状态; 锂离子电池; 深度学习; 编解码结构; 自注意力机制

基金项目: 内蒙古纪检监察大数据实验室开放课题基金(No.IMDBD20200220)

中图分类号: TM912; TP183 **文献标识码:** A **文章编号:** 0372-2112(2023)01-0050-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20211640

State-of-Charge Estimation of Lithium-ion Battery Based on Informer and Its Sparse Optimization Method

HE Ying-jie, LIU Yue-feng, BIAN Hao-dong, GUO Wei, ZHANG Xiao-yan

(School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou, Inner Mongolia 014010, China)

Abstract: Accurate estimation of the state of charge (SOC) is an important basis for extending the battery life and ensuring the safety of electric vehicles. Traditional deep learning estimation methods suffer from inefficient parallelization and lengthy training time. To this end, the Informer model based on the self-attention mechanism is used to estimate the battery SOC, which reduces the time complexity of the traditional self-attention and training time, increases the hardware usage. It is more accurate than other deep learning methods. However, the Informer model still has the problems of large and redundant parameters, therefore a sparse optimization method is proposed. The iterative magnitude pruning method based on the lottery ticket hypothesis is used to sparse the Informer, highlighting the dominant attention feature and improving model estimation accuracy while reducing parameter redundancy. The proposed sparse-Informer's root mean square error and mean absolute error are 0.383 0% and 0.285 8% at room temperature, respectively. The mean absolute error is decreased by 25% compared to Informer model. Additionally, the generalization ability to estimate the SOC across other lithium-ion battery types is confirmed. When performing battery SOC estimation, this model outperforms other established deep learning models in terms of training speed, estimation accuracy and stability.

Key words: state of charge; lithium-ion battery; deep learning; encoder and decoder; self-attention mechanism

Foundation Item(s): Inner Mongolia Discipline Inspection and Supervision Big Data Laboratory Open Project Fund (No.IMDBD20200220)

1 引言

发展新能源汽车是应对气候变化、推动绿色发展的重要战略举措^[1]. 我国新能源汽车产业以发展纯电

动汽车为主, 其中锂离子电池因具备长使用寿命、低自放电率、高能量密度、零记忆效应等优势成为现在电动汽车的主要供能系统^[2]. 为确保电动汽车在运行过程

中的安全和稳定,需要电池管理系统(Battery Management System, BMS)对电池状态进行监测,其中最重要的是电池荷电状态(State Of Charge, SOC)^[3]. 电池 SOC 代表电池中的剩余电量,又间接表示电动汽车的剩余行驶里程. 准确的 SOC 估计给驾驶员提供车辆状态信息,可避免出现电池过充或过放等不良情况,保证了汽车使用过程中的安全性^[4]. 但在现存传感器技术下,电动汽车运行过程中的电池 SOC 无法直接测量得到,需通过相关变量信息间接估计,使得对电池 SOC 的准确估计成为一大难题.

电池 SOC 估计作为电池研究的基础课题,一直是该领域的研究热点,几十年来研究人员对电池 SOC 的估计进行了多方面探索. 现存估计电池 SOC 的方法包括传统估计方法、基于模型的方法以及数据驱动法^[5]. 由于目前传统估计方法和基于模型估计方法核心技术突破困难,使研究人员将更多目光转向数据驱动方法. 基于数据驱动的方法可以直接将可测量变量如电流、电压、温度等直接映射为电池 SOC,并针对不同电池类型和驾驶工况都可进行有效估计. 数据驱动的方法有很多,其中基于深度学习的方法因其强大的非线性映射能力而获得了广泛关注^[6]. 其中, Ephrem Chemali 等人^[7]在 2017 年应用长短期记忆神经网络(Long Short Term Memory, LSTM)方法直接对电池 SOC 进行估计,其在不使用滤波器的情况下,就将室温下 SOC 估计平均绝对误差(Mean Absolute Error, MAE)提高到 0.573%,掀起了应用深度学习对电池 SOC 估计的研究热潮. 在文献[8]中,作者引入门控循环单元神经网络(Gated Recurrent Unit, GRU)对电池 SOC 进行估计,在多温度环境下 MAE 可达到 0.86%. 还有研究人员^[9]采用深度卷积神经网络(Convolutional Neural Network, CNN)在变化环境温度下均方根误差(Root Mean Square Error, RMSE)达到 2%. 此外,也有研究^[10]将卷积神经网络和循环神经网络相结合,在无温度输入条件下 MAE 可达到 0.402 7%.

现存大多数深度学习 SOC 估计方法均已获得可观的估计效果. 但仍存在一些问题,如大多数方法以 LSTM 和 GRU 为主,虽已获得了不错的估计效果. 但是这类循环神经网络训练过程较难,需要很长的时间才能使模型收敛,通常需要好几个小时甚至是几天的时间. 同时这类神经网络结构无法并行化,不能很好的利用图形处理器(Graphics Processing Unit, GPU)的运算性能. 此外,循环神经网络的变体在面对更长序列时仍存在不可避免的缺陷. 因此,近期研究人员使用 Transformer^[11]等结构代替了 RNN,并已在计算机视觉以及自然语言处理领域取得了显著成果. Informer^[12]在 Transformer 的基础上,通过其提出的概率稀疏自注意力和注

意力蒸馏机制降低原始 Transformer 在长序列输入下的时间复杂度和内存占用率问题,已提高了电力变压器温度、用电负荷和天气预测的能力,但是这种模型结构存在数据冗余问题.

基于此,本文提出基于 Informer 及其稀疏优化方法估计电动汽车锂离子电池 SOC. 首先,通过 Informer 充分挖掘电池可测量变量间的时空特征,实现电池 SOC 的准确估计. 其次,利用基于彩票假设的幅值迭代剪枝方法处理由自注意力机制导致的参数冗余问题,降低模型参数量,同时其稀疏结构可突出主要注意力特征图,进一步提升了模型估计精度. 与现存的多种深度学习估计方法相比,稀疏化 Informer 模型在大幅度缩短训练时间的基础上有较好的特征提取和预测能力.

2 Informer 模型及稀疏优化方法

Informer 模型整体结构由编码器和解码器两部分组成. 编解码器包含位置信息嵌入层、多头概率稀疏自注意力层和卷积蒸馏层. 其基本思想是:使用位置信息嵌入层对输入序列进行时间编码,后采用多个由多头概率稀疏自注意力和卷积层组成的神经网络模块进行深度特征提取,解码器上输入的电池相关变量信息通过与编码器上提取的深度特征图进行运算,捕获特征间的相关性,最终通过全连接层得到估计的电池 SOC 值. Informer 模型整体结构如图 1 所示.

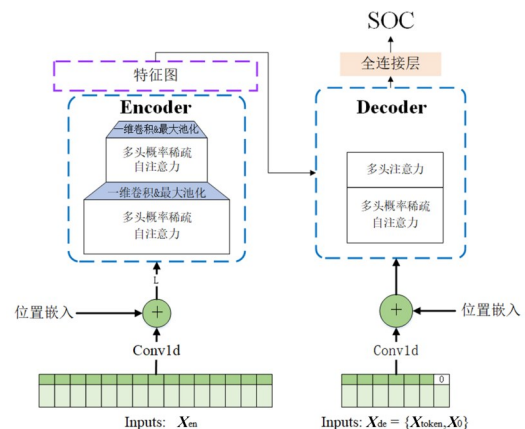


图 1 Informer 网络结构示意图

2.1 Informer 网络结构

2.1.1 位置嵌入层

使用 Transformer 结构解决时间序列预测问题需要通过位置编码为输入特征添加上下文信息,即相关时间信息. 位置编码的方式有很多^[13],这里对每一个时刻的输入信息按正余弦函数的线性变换进行位置编码,以此来获取某一时刻的输入信息在整个输入序列中的

位置. 具体计算方式如下:

$$PE_{(\text{pos}, 2i)} = \sin\left(\frac{\text{pos}}{10000^{2i/d_{\text{model}}}}\right) \quad (1)$$

$$PE_{(\text{pos}, 2i+1)} = \cos\left(\frac{\text{pos}}{10000^{2i/d_{\text{model}}}}\right) \quad (2)$$

其中 pos 和 i 分别表示当前数据在输入序列中的位置和维度, d_{model} 是对原始数据进行升维操作时设定的维度.

2.1.2 概率稀疏自注意力

原始 Transformer 中自注意力采用标准的点积计算方式, 导致每个注意力层的时间复杂度为 $O(L^2)$, 随着输入序列的增长, 其运算复杂度将呈平方方式上升. 并且长输入序列堆叠层总内存使用量为 $O(J \times L^2)$, 这限制了模型的可伸缩性.

通过对注意力得分可视化分析, 周在文献[12]中得出原始自注意力得分存在长尾分布特点的结论, 并提出概率稀疏自注意力. 首先, 对整体查询向量进行重要性评估, 由超参数 μ 决定采用多少的查询向量进行后续的点积计算, 剩余的查询向量则直接赋值为均值. 概率稀疏自注意力算法具体计算过程如算法 1 所示.

算法 1 概率稀疏自注意力

准备条件: Tensor $Q \in R^{m \times d}, K \in R^{n \times d}, V \in R^{n \times d}$

- 1: 设置超参数 $c, u = c \ln(m)$ 和 $U = m \ln(n)$ (其中 m 为查询矩阵序列维度, n 为键矩阵和值矩阵序列维度)
- 2: 从 K 中随机选取 U 个点积对组成 \bar{K} (\bar{K} 即为每个 query 都随机采样部分的键值矩阵)
- 3: 计算采样得分 $\bar{S} = Q\bar{K}^T$
- 4: 按行计算稀疏性得分 $M = \max(\bar{S}) - \text{mean}(\bar{S})$
- 5: 选取 M 中得分最高的 u 个查询向量组成新的稀疏查询矩阵 \bar{Q}
- 6: 计算概率稀疏注意力得分 $S_1 = \text{softmax}(\bar{Q}\bar{K}^T / \sqrt{d})V$
- 7: 剩余查询向量不参与点积计算直接取均值及最后得分, $S_0 = \text{mean}(V)$
- 8: 最终得到自注意力特征图为 $S = \{S_1, S_0\}$

通过式(3)判断查询向量稀疏性.

$$\bar{M}(q_i, K) = \max_j \left\{ \frac{q_i k_j^T}{\sqrt{d}} \right\} - \frac{1}{L_k} \sum_{j=1}^{L_k} \frac{q_i k_j^T}{\sqrt{d}} \quad (3)$$

\bar{M} 用来计算第 i 个查询向量与键矩阵的相关度. 其中, j 表示键矩阵的第 j 个键向量. 运用此方法的具体思想是因为在注意力点积对运算过程中, 突出的点积对所对应的查询向量注意力概率分布远离均匀分布.

2.1.3 多头自注意力

多头自注意力机制将输入映射到不同的子空间, 可以使模型从不同角度理解输入序列, 使最终的输出融合更多角度的特征信息. 计算过程由式(4)(5)所示. 其中 H 表示注意力头数量, 可训练参数矩阵

$W^O \in R^{d_m \times d_m}, W^{Q,K,V} \in R^{d_m \times d_k}, d_k = d_m/H.$

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_H)W^O \quad (4)$$

$$\text{head}_h = \text{probSparseAttention}(QW_h^Q, KW_h^K, VW_h^K) \quad (5)$$

2.1.4 编码器结构

具体的编码器结构如图 1 左部所示. 编码器主要作用为提取输入序列长距离相关性以及输入数据的深度特征. 考虑到概率稀疏自注意力计算过程中, 剩余注意力值较低的查询向量在最终运算中直接取平均值. 为了在深层特征提取过程中使模型结构更多地关注主导注意力, 突出其作用, 这里采用卷积和池化操作对自注意力特征图进行蒸馏, 对具有支配作用的优势特征进行特权化特征提取. 从第 j 层到第 $j+1$ 层推进的实现过程由式(6)表示.

$$X'_{j+1} = \text{MaxPool}(\text{ELU}(\text{Conv 1d}[\text{X}'_j]_{AB}))) \quad (6)$$

2.2 基于彩票假设的幅值迭代剪枝方法

通过对自注意力机制中的注意力得分分布分析可以看出, 少部分的点积对主导注意力贡献大, 剩余贡献小. 对小影响点积对计算的权值进行置零操作, 仅保留一定比例的大权重, 使自注意力计算过程中主要关注有用部分, 突出主导注意力, 使模型具有挖掘深度特征能力, 进而提升预测精度.

这里采用基于彩票假设的幅值迭代剪枝 (Iterative Magnitude Pruning, IMP) 方法^[14]. 通过对一个前馈神经网络进行幅值迭代剪枝找到一个可以重新训练的稀疏子网络, 对子网络进行训练便可达到与原始网络相近的性能. 甚至经过多次训练后, 稀疏子网络性能会优于原始稠密网络. 研究人员发现, 使用原始网络的初始化权重对子网络进行初始化, 效果会优于使用随机权重初始化的子网络, 所以本方法采用 IMP 算法从基于 Informer 的电池 SOC 估计模型中筛选最优子网络, 步骤如图 2 所示.

3 Informer 模型实验结果分析

3.1 实验环境与测试

实验使用了两种不同锂离子电池的数据集分别为 LG-HG2^[15] 和 Panasonic18650^[7]. 参与训练的数据包括电流、电压、温度和电池 SOC 值, 数据采样间隔为 1 s. 为了在第 6 节中与其他网络模型进行比较, 本文参照了文献[16]中的数据划分方式. LG-HG2 数据集集中的 UDDS, LA92, US06 作为测试集; 室温条件下 Panasonic 数据集集中的 UDDS, LA92, US06 作为测试集, 变化温度条件下将 Cycle1~4 作为测试集, 其余作为训练集和验证集.

本文选用最大最小值归一化方法对数据进行预处理. 使用平滑的平均绝对误差 (Huber Loss) 作为损失函

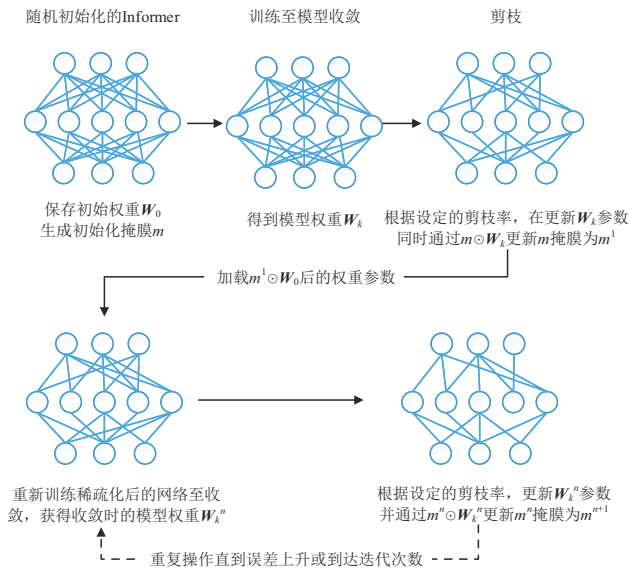


图2 基于彩票假设的幅值迭代剪枝过程示意图

数, Adam 作为优化器, 学习率策略为带热重启 (warmup) 的余弦退火 (cosine decay) 技术. 通过多次试验确定超参数 $batchsize$ 为 64, 注意力头数为 12, 概率稀疏注意力稀疏程度 c 为 10, 编码器步长为 64, 解码器步长为 32.

3.2 室温下的 Informer 估计结果

这一节, 使用 25°C 下数据集去训练和验证模型. 数据集划分详见 3.1, 选用 MAE 和 RMSE 评价模型预

测能力. 模型具体估计结果如表 1 所示. 其中平均的 MAE 和 RMSE 分别是 0.35% 和 0.45%. 实验结果证明, Informer 模型可以直接通过可测量变量映射电池 SOC, 并且在单温度条件下获得了可靠准确的估计效果.

表 1 25°C 下 Informer 模型估计结果

指标	工况		
	UDDS	LA92	US06
RMSE/%	0.375 0	0.394 4	0.582 7
MAE/%	0.297 8	0.315 9	0.454 7

3.3 多温度下的估计结果

电池在不同的温度条件下具有不同的化学特性会导致电池放电行为的差异. 例如, 在 0°C 下无再生制动能量. 本节在多种温度条件下去训练网络, 验证模型在多温度条件下的预测能力. 数据划分同上一节, 但由于 LG 数据集包含六种温度条件, 这里的训练数据将包含 6×8 个循环. 多温度条件下训练的模型在各个温度下的估计结果如表 2 所示.

在多温度数据集训练下, 获得最终的平均 MAE 和 RMSE 为 0.427 3% 和 0.500 5%. 从表 2 中可以看出, 本文提出的 Informer 模型可对多种温度条件下的电池 SOC 进行估计, 即使在低温 -20°C 下平均 MAE 也达到了 0.36%.

表 2 多温度条件下的估计结果

温度/ $^\circ\text{C}$	工况								
	LA92			US06			UDDS		
	MAE/%	RMSE/%	MAX/%	MAE/%	RMSE/%	MAX/%	MAE/%	RMSE/%	MAX/%
0	0.399 2	0.473 4	1.471 2	0.532 3	0.614 7	1.820 1	0.364 7	0.418 2	0.936 2
10	0.415 7	0.484 9	1.365 5	0.539 1	0.627 1	2.021 7	0.389 0	0.454 2	1.336 7
25	0.435 1	0.506 5	1.337 9	0.528 8	0.636 3	2.063 0	0.391 0	0.446 9	1.040 7
40	0.454 1	0.541 0	1.309 5	0.581 1	0.680 6	2.127 2	0.397 4	0.477 5	1.367 3
-10	0.375 5	0.438 4	1.137 9	0.457 2	0.538 2	1.692 6	0.340 4	0.389 3	0.795 2
-20	0.351 1	0.415 8	1.283 7	0.389 5	0.466 1	1.723 5	0.351 5	0.401 4	0.826 2

4 稀疏化 Informer 实验分析

通过上一节的实验结果可以看出, 运用 Informer 结构可以有效估计电池 SOC. 并且与文献 [16] 相比, 其输入所需时间步长更短, 其他估计方法均需要上百的时间步长才可进行有效估计. Informer 方法虽然训练快, 估计精度高, 但其模型体量巨大. 上一节所用模型参数量为 14×10^6 . 为解决参数量过大的问题, 本文使用基于彩票假设的 IMP 算法对 Informer 模型进行压缩, 即本文提出的稀疏化 Informer 模型.

在本小节将探索不同剪枝率对最终模型估计效果的影响, 分别将剪枝率设置为 10%, 20%, 40% 和 60%.

具体对应剪枝迭代次数为 12, 6, 3, 2, 估计结果如表 3 所示. 通过表 3 中的估计结果可以看出, 使用幅值迭代剪枝方法实现了在降低模型参数量的同时提升模型估计精度. 根据剪枝率的不同, 其对模型估计效果提升的影响也不尽相同. 通过两种评价指标的对比可以看出, 剪枝对 MAE 的影响更大, 提升较为明显.

图 3 展示了单温度训练条件下不同剪枝率模型在室温 LA92 上的估计结果. 图 4 展示了多温度训练条件下稀疏模型在低温 (-20°C), 0°C , 高温 (40°C) 下的电池 US06 工况 SOC 估计结果. 根据图 5 展现的模型估计效果可看出, 本文所提稀疏优化方法可以有效提升模

表3 稀疏化 Informer 在单温度及多温度下的估计结果

剪枝率	剪枝迭代次数 (最优/全部)	室温/多温度		参数数量($\times 10^6$)	减去参数量
		RMSE/%	MAE/%		
不剪枝	—	0.445 6/0.500 5	0.388 3/0.427 3	14.092 633	0
10%	9/12	0.383 0/0.641 5	0.285 8/0.491 7	5.479 422	61.12%
20%	4/6	0.401 8/0.369 3	0.313 7/0.292 3	5.838 433	58.91%
40%	1/3	0.519 3/0.417 2	0.382 8/0.361 3	8.460 227	40%
60%	1/2	0.577 4/0.380 1	0.437 4/0.278 2	5.648 327	59.92%

型性能,并且在室温条件及多温度条件下均能实现稳定估计.





图3 25 °C下不同剪枝率的模型在LA92的估计结果对比图

将编码器最终输出的特征图进行可视化处理,如图5所示,上图为原始 Informer 模型的特征图,下图为60%剪枝率下稀疏 Informer 的特征图.可以看出,原始 Informer 模型的特征图权重分散,而稀疏化后的特征图仅对某些位置赋予更高的权重,剩余部分权重分布较为平均.


根据实验结果可知,稀疏化 Informer 具有准确估计电池荷电状态的能力,剪枝率的不同也影响了最终模型的估计精度,但均比原始的 Informer 模型有所提升.本文中使用了10%剪枝率的稀疏化 Informer 模型,迭代9次后在两种温度条件下均达到最优效果,但由于迭代次数较多导致其训练时间也是最长的.而使用大剪枝率的稀疏模型,在不损失估计精度的前提下用时短,稀疏程度高.最终,综合考虑模型估计精度、剩余参数量以及模型运行时间,之后的泛化性能测试使用了60%剪枝率下的稀疏化 Informer 模型进行实验.

5 稀疏化 Informer 泛化实验


生活中的电动汽车供电系统因所含化学性质有不同的差异,不同的化学性质在使用过程中有不同的充放电行为.这里将上述所训练出的最优模型作为预训练模型,冻结前面参数只使用 Panasonic 电池数据对模型最后一层进行重新训练,并且使用不同量级的数据



(a) -20 °C估计曲线对比图



(b) 0 °C估计曲线对比图



(c) 40 °C估计曲线对比图

图4 不同稀疏程度模型在US06工况下的估计曲线对比图

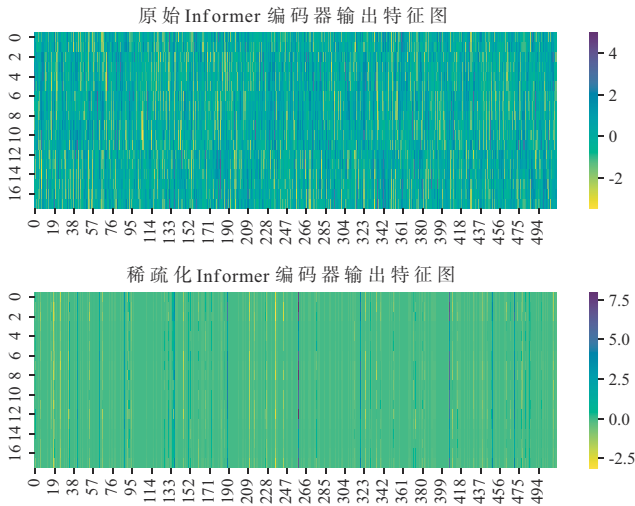


图5 编码器最终特征图可视化

对其进行训练,具体结果如表4所示.

表4 稀疏化 Informer 泛化性能实验结果

训练数据数量	室温/变化温度	
	RMSE/%	MAE/%
20%	0.492 0/0.366 8	0.350 8/0.293 2
40%	0.463 8/0.432 6	0.350 3/0.355 7
60%	0.260 2/0.354 3	0.218 2/0.303 3
80%	0.327 3/0.366 2	0.276 0/0.291 1
100%	0.395 5/0.355 0	0.344 2/0.295 3

泛化性能实验结果表明本文提出的稀疏化 Informer 在其他类型电池数据集上仍能实现准确的 SOC 估计. 并且与其他需使用大量训练集的方法相比,本文在预训练模型基础上仅使用原训练数据集的 20% 即可在变化温度环境中实现高精度估计, MAE 和 RMSE 分别可达到 0.29% 和 0.36%. 同时,以室温条件下的训练状况为例,在训练数据集数量递减的过程中,其测试结果呈现了先上升后下降的变化趋势,造成这种现象的原因可以归结于训练数据的量级对稀疏化网络模型学习特征的偏向影响. 由此得知,在使用这种迁移学习方式对模型训练数据的选择亦是影响模型估计性能的重要因素,但整体估计性能仍保持了一个较高的水平. 表4展示了本文模型在不同数据条件下的估计性能,证明了稀疏化 Informer 具有在复杂情况下准确估计其他类型锂离子电池 SOC 的能力.

6 讨论

将本文提出的稀疏化 Informer 模型与原始 Informer 模型、Transformer 模型、卷积神经网络、循环神经网络和混合神经网络方法进行对比,具体估计结果如表5所示. 通过对表格进行分析比较,可以看出本文提出的稀

疏化模型相较于其他模型展现出了较高的估计精度,且获得的估计效果更为稳定.

表5 不同模型估计结果比较

方法	类型	RMSE/%	MAE/%
		室温/多温度	室温/多温度
稀疏化 Informer	Transformer	0.401 8/0.380 1	0.313 7/0.278 2
Informer	Transformer	0.519 7/0.500 5	0.391 5/0.427 3
S-Transformer	Transformer	0.905 6/1.191 4	0.445 9/0.650 2
GRU	Recurrent	1.068 6/1.385 6	0.487 7/0.584 7
LSTM	Recurrent	1.138 1/1.449 8	0.534 1/0.730 0
Resnet	Convolutional	1.334 9/1.363 6	0.785 9/0.777 1
FCN	Convolutional	1.555 5/1.780 8	0.964 2/1.081 0
GRU-FCN	Hybird	1.447 7/1.621 5	0.822 8/0.926 9
LSTM-FCN	Hybird	1.777 1/1.924 8	1.195 4/1.155 2

7 结论

本文首先运用 Informer 模型对电池 SOC 进行估计,其在提升估计精度的基础上,降低了传统自注意力的运算时间复杂度及内存占用空间. 后利用基于彩票假设的幅值迭代剪枝方法对 Informer 进行优化,提出的稀疏化 Informer 减少了自注意力计算中全连接结构造成的参数冗余,提升了原始模型估计精度. 在不同温度条件和不同类型电池数据条件下验证了模型的可靠性和泛化性. 在室温条件下最优的 MAE 可达到 0.21%,多温度测试条件下平均 MAE 可达到 0.27%. 所得结论如下: (1)该模型计算精度高,且对整个循环周期的估计效果都较为稳定;(2)相较于其他基于神经网络的方法,如 LSTM、CNN 等,本方法训练速度更快,硬件使用率更高;(3)与原始的 Informer 模型相比,稀疏化 Informer 在降低模型参数量的同时提高了估计精度,参数量的下降促进了本文方法在电动汽车运行平台的应用潜能;(4)在新类型电池数据集数据量有限的条件下,本方法也能达到较高精度的估计效果,对于其他类型电池具有较强的适应能力.

本文工作建立在大量有标签数据集训练的基础上,后续工作将探索在无标签数据集条件下如何使模型进行高精度电池 SOC 估计.

参考文献

[1] 付诗意, 吕桃林, 闵凡奇, 等. 电动汽车用锂离子电池 SOC 估算方法综述[J]. 储能科学与技术, 2021, 10(3): 1127-1136.
 FU Shi-yi, LV Tao-lin, MIN Fan-qi, et al. Review of estimation methods on SOC of lithium-ion batteries in electric vehicles[J]. Energy Storage Science and Technology, 2021, 10(3): 1127-1136. (in Chinese)

- [2] WANG Yu-jie, TIAN Jia-qiang, SUN Zhen-dong, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems[J]. *Renewable and Sustainable Energy Reviews*, 2020, 131: 110015. DOI: 10.1016/j.rser.2020.110015.
- [3] 张照妮, 郭天滋, 高明裕, 等. 电动汽车锂离子电池荷电状态估算方法研究综述[J]. *电子与信息学报*, 2021, 43(7): 1803-1815.
Zhang Zhao-wei, GUO Tian-zi, GAO Ming-yu, et al. Review of socestimation methods for electric vehicle li-ion batteries[J]. *Journal of Electronics & Information Technology*, 2021, 43(7): 1803-1815. (in Chinese)
- [4] HANNAN M A, LIPU M S H, HUSSAIN A, et al. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations[J]. *Renewable and Sustainable Energy Reviews*, 2017, 78: 834-854.
- [5] Hu Xiao-song, Feng Fei, Liu Kai-long, et al. State estimation for advanced battery management: Key challenges and future trends[J]. *Renewable and Sustainable Energy Reviews*, 2019, 114: 109334.
- [6] HOSSAIN LIPU M S, HANNAN M A, KARIM T F, et al. Intelligent algorithms and control strategies for battery management system in electric vehicles: Progress, challenges and future outlook[J]. *Journal of Cleaner Production*, 2021, 292: 126044. DOI: 10.1016/j.jclepro. 2021. 126044.
- [7] 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.
- [8] LI Chao-ran, XIAO Fei, FAN Ya-xiang. An approach to state of charge estimation of lithium-ion batteries based on recurrent neural networks with gated recurrent unit[J]. *Intergies*, 2019, 12(9): 1592.
- [9] HANNAN M A, HOW D N T, LIPU M S H, et al. SOC estimation of li-ion batteries with learning rate-optimized deep fully convolutional network[J]. *IEEE Transactions on Power Electronics*, 2021, 36(7): 7349-7353.
- [10] HUANG Zhe-lin, YANG Fang-fang, XU Fan, et al. Convolutional gated recurrent unit-recurrent neural network for state-of-charge estimation of lithium-ion batteries[J]. *IEEE Access*, 2019, 7: 93139-93149.
- [11] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. New York: Curran Associates Inc, 2017: 6000-6010.
- [12] ZHOU Hao-yi, ZHANG Shang-hang, PENG Jie-qi, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[C]//*Proceedings of the 35th Association for the Advancement of Artificial Intelligence (AAAI)*. New York: AAAI, 2021: 11106-11115.
- [13] GEHRING J, AULI M, GRANGIER D, et al. Convolutional sequence to sequence learning[C]//*Proceedings of the 34th International Conference on Machine Learning - Volume 70*. Sydney: JMLR.org, 2017: 1243-1252.
- [14] FRANKLE J, CARBIN M. The lottery ticket hypothesis: Finding sparse, trainable neural networks[C]//*International Conference on Learning Representations(ICLR)*. New Orleans: OpenReview.net, 2019.
- [15] Vidal C, Kollmeyer P, Chemali E, et al. Li-ion battery state of charge estimation using long short-term memory recurrent neural network with transfer learning[C]//*2019 IEEE Transportation Electrification Conference and Expo (ITEC)*. New York: IEEE, 2019: 1-6.
- [16] HANNAN M A, HOW D N T, LIPU M S H, et al. Deep learning approach towards accurate state of charge estimation for lithium-ion batteries using self-supervised transformer model[J]. *Sci Rep*, 2021, 11(1): 19541.

作者简介



何滢婕 女, 1998 年出生, 山西太原人. 现为内蒙古科技大学信息工程学院计算机系硕士研究生. 从事电动汽车电池状态估计及深度学习方面的研究.

E-mail: 1353517169@qq.com



刘月峰(通讯作者) 男, 1977 年出生, 博士. 现为内蒙古科技大学副教授. 主要研究方向为机器学习、知识图谱、图像处理、大数据分析与应用.

E-mail: liuyuefeng01035@163.com