



## 基于SDAE-DCPInformer的电动汽车电池SOC和SOH估算方法

彭自然, 王顺豪, 肖伸平

引用本文:

彭自然, 王顺豪, 肖伸平. 基于SDAE-DCPInformer的电动汽车电池SOC和SOH估算方法[J]. *智能系统学报*, 2025, 20(4): 969–983.

PENG Ziran, WANG Shunhao, XIAO Shenping. SOC and SOH estimation method of electric vehicle battery based on SDAE-DCPInformer[J]. *CAAI Transactions on Intelligent Systems*, 2025, 20(4): 969–983.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202408010>

## 您可能感兴趣的其他文章

### 基于力传感的系留无人机定位方法研究

Research on the positioning method of tethered UAV using force sensing  
*智能系统学报*. 2020, 15(4): 672–678 <https://dx.doi.org/10.11992/tis.201907015>

### 受成本约束的电力信息物理相依系统鲁棒性优化设计

Robust optimization design of an electrical cyber–physical system based on constrained cost  
*智能系统学报*. 2020, 15(3): 623–632 <https://dx.doi.org/10.11992/tis.201812034>

### 基于大变异遗传算法进行参数优化整定的负荷频率自抗扰控制

Active disturbance rejection control of load frequency based on big probability variation's genetic algorithm for parameter optimization  
*智能系统学报*. 2020, 15(1): 41–49 <https://dx.doi.org/10.11992/tis.201906026>

### 基于GABP-KF的WSN数据漂移盲校准算法

GABP-KF-based blind calibration algorithm of data drift in wireless sensor networks  
*智能系统学报*. 2019, 14(2): 254–262 <https://dx.doi.org/10.11992/tis.201712003>

### 快速双非凸回归算法及其电力数据预测应用

Fast double nonconvex regression algorithm for forecast of electric power data  
*智能系统学报*. 2018, 13(4): 665–672 <https://dx.doi.org/10.11992/tis.201708033>

### 需求侧管理下智能家庭用电多目标优化控制

Multiobjective optimization control of intelligent household electricity with demand management  
*智能系统学报*. 2018, 13(1): 125–130 <https://dx.doi.org/10.11992/tis.201705030>

DOI: 10.11992/tis.202408010

网络出版地址: <https://link.cnki.net/urlid/23.1538.TP.20250423.1408.002>

# 基于 SDAE-DCPInformer 的电动汽车 电池 SOC 和 SOH 估算方法

彭自然<sup>1,2</sup>, 王顺豪<sup>1,2</sup>, 肖伸平<sup>1,2</sup>

(1. 湖南工业大学 电气与信息工程学院, 湖南 株洲 412007; 2. 湖南工业大学 湖南省电传动控制与智能装备重点实验室, 湖南 株洲 412007)

**摘要:** 针对现有电动汽车电池状态估计方法存在运算效率低和估算准确率低的问题, 提出一种模型以估算电动汽车电池荷电状态 (state of charge, SOC) 和健康状态 (state of health, SOH)。采用堆叠降噪自编码器 (stacked denoising auto encoder, SDAE) 清洗电压、电流和温度数据中的异常数据和空缺数据, 减小对估算精度的影响。引入动态通道剪枝 (dynamical channel pruning, DCP) 技术对 Informer 模型进行稀疏化处理, 提高剪枝后模型的性能和稳定性。将清洗过的数据输入 DCPInformer 模型实现 SOC 和 SOH 的精确估计。实验结果表明, 所提出的 SDAE-DCPInformer 模型估计 SOC 的平均绝对误差和均方根误差分别达到 0.25% 和 0.38%, 估计 SOH 的平均绝对误差和均方根误差分别达到了 0.51% 和 0.64%。与传统 Transformer 等模型相比, 所提模型预测 SOC 和 SOH 的速度更快, 估算准确度有效提升, 拥有的更好稳定性和泛化性。

**关键词:** 电动汽车; 动力电池; 荷电状态; 健康状态; 堆叠降噪自编码器; 数据清洗; 动态通道剪枝; 改进 Informer  
**中图分类号:** TP274; U469.72; TM912 **文献标志码:** A **文章编号:** 1673-4785(2025)04-0969-15

中文引用格式: 彭自然, 王顺豪, 肖伸平. 基于 SDAE-DCPInformer 的电动汽车电池 SOC 和 SOH 估算方法 [J]. 智能系统学报, 2025, 20(4): 969-983.

英文引用格式: PENG Ziran, WANG Shunhao, XIAO Shenping. SOC and SOH estimation method of electric vehicle battery based on SDAE-DCPInformer[J]. CAAI transactions on intelligent systems, 2025, 20(4): 969-983.

## SOC and SOH estimation method of electric vehicle battery based on SDAE-DCPInformer

PENG Ziran<sup>1,2</sup>, WANG Shunhao<sup>1,2</sup>, XIAO Shenping<sup>1,2</sup>

(1. Department of Electrical and Information Engineering, Hu'nan University of Technology, Zhuzhou 412007, China; 2. Hu'nan Electrical Transmission and Intelligent Equipment Key Laboratory, Hu'nan University of Technology, Zhuzhou 412007, China)

**Abstract:** To address the problems of low computing efficiency and estimation accuracy of existing electric vehicle power battery state of charge (SOC) and state of health (SOH) estimation methods, a model is proposed to estimate SOC and SOH. First, a stacked denoising automatic encoder (SDAE) is used to clean the anomalies and vacancies in the voltage, current, and temperature data to reduce the effect on the estimation accuracy. Second, the dynamic channel pruning (DCP) technique is introduced to address the sparsity of the Informer model to improve the performance and stability of the model. Finally, the cleaned data are input into the DCPInformer network model to estimate SOC and SOH. Experiments reveal that the mean absolute error (MAE) and root mean square error (RMSE) of the proposed SDAE-DCPInformer model reach 0.25% and 0.38% for estimating SOC, respectively, and the MAE and RMSE for estimating SOH reach 0.51% and 0.64%, respectively. Compared with traditional models such as the Transformer, the proposed model predicts faster, and the estimation accuracy is improved with better stability and generalization.

**Keywords:** electric vehicle; power battery; state of health; state of charge; stacked denoising autoencoder; data cleaning; dynamical channel pruning; enhanced informer

电动汽车动力电池是为电动汽车提供能量的

核心部件, 通常由锂离子电池构成, 具有高能量密度和长续航能力<sup>[1-2]</sup>。动力电池容量衰退的影响因素主要分为环境温度变化、组合成组方式、充电和放电速率等。电池容量衰退会导致电池性能下降, 极可能使电池内部温度升高进而引发热

收稿日期: 2024-08-20. 网络出版日期: 2025-04-23.

基金项目: 国家重点研发计划基金项目 (2019YFE0122600); 湖南省教育厅重点科研项目 (22A0423); 湖南省自然科学基金项目 (2023JJ60267, 2022JJ50073).

通信作者: 彭自然. E-mail: [pengziran@hut.edu.cn](mailto:pengziran@hut.edu.cn).

失控现象,形成着火隐患<sup>[3-5]</sup>。因此,电池管理系统应该准确估算电动汽车动力电池的荷电状态 (state of charge, SOC) 和健康状态 (state of health, SOH) 以提升电动汽车整体安全性,改善驾驶员的行驶体验<sup>[6-8]</sup>。

基于模型和基于数据驱动的估算是获取当前动力电池 SOC 与 SOH 的主要方法<sup>[9-11]</sup>。基于模型的估算方法一般通过搭建体现电池内部物理机制的一阶和二阶电阻电容等效电路模型,结合电压、电流等数据动态的调整电路设置从而完成电池状态估算。基于数据驱动的估算方法主要是利用人工智能神经网络分析不同工况下的实时电压、电流和温度数据估算电池状态,具有实时性好、适应性强和较高的灵活性和扩展性的优点,因此基于数据驱动的估算方法被广泛应用于实际电池状态估算。

深度学习的自我优化能力使其能够处理大规模数据,能够自动进行预测和决策<sup>[12-14]</sup>。文献 [15] 采用双层集成极限学习机模型解决单体极限学习机不稳定的问题,确定合适的电池健康特征并拟合与健康状态 SOH 的关系。然而,该方法非常依赖数据特征的提取,且无视原始数据与 SOH 及 SOC 之间的复杂关系。文献 [16] 提出了将测得的容量值作为长短时记忆神经网络的输入,有效减轻电池衰退对荷电状态估计的影响。文献 [17] 提出了将 SOH 值作为特征依据门控循环单元完成 SOC 的估算。然而,上述两种方法均基于传统循环神经网络,需要依次计算每一个时间步的输出,存在难以处理大规模数据的缺点。

目前在机器翻译和计算机视觉两种领域具有卓越表现的大模型 Transformer 逐渐应用于实时数据预测任务<sup>[18]</sup>。文献 [19] 提出采用 Transformer 模型实现多因素条件下双时间尺度退化设备剩余寿命的估算。但目前的模型 Transformer 存在着自注意力机制导致的二次计算等不足之处需要改进。文献 [20] 使用了在训练和推理效率方面更强的模型 Informer,充分挖掘电压等数据的信息实现 SOH 估算。然而,随着网络结构的不断深入,Transformer 和 Informer 等模型面临着严重的参数冗余问题,导致模型复杂度增加。

另外,采集数据的传感器非常容易受到硬件损坏或老化、信号干扰和连接松动的问题,会出现数据质量差等问题从而影响电池状态的估算,因此必须进行数据清洗处理<sup>[21-23]</sup>。文献 [24] 和文献 [25] 均提出通过降噪自编码器清洗数据,有效

提升电池寿命的估算准确度。但单层降噪自编码器通常只有一个编码层,灵活性和扩展性较差。当噪声过多时,模型难以捕捉复杂数据的高级特征,进而影响了模型的整体性能。

针对上述问题,本文提出一种预测模型解决电池状态估算过程中存在的问题,具体贡献为:

1) 面向单层降噪自编码器不稳定的问题,提出堆叠降噪自编码器 (stacked denoising auto encoder, SDAE) 对电动汽车传感器采集的数据进行清洗,重新构建输入数据,提高模型训练质量,提升态势感知性能。

2) 针对模型 Transformer 在电池状态估算任务的不足,采用 Informer 模型作为任务模型并采用动态通道剪枝 (dynamical channel pruning, DCP) 技术对 Informer 模型进行压缩,提高模型轻量化和运行效率,保持模型的性能和稳定性。

3) 将 DCPIformer 模型作为 SOC 和 SOH 的估算模型,依据清洗后的数据得到当前循环的 SOC 变化情况。基于 SOC 的变化趋势能够反应实际电池最大容量的变化,采用 DCPIformer 模型估算整个循环的 SOH,实现 SOC 和 SOH 的实时性估算。

## 1 电池分析和制定模型

### 1.1 电池管理系统

电动汽车电池包由电芯和电池管理系统 (battery management system, BMS) 组成,电芯按照特定的方式串联和并联组成。串联方式提升电池包电压,并联方式增加电池包的容量。动力电池组内部结构如图 1 所示。



图 1 动力电池组内部结构

Fig. 1 Power battery pack internal structure

BMS 由电池监控单元、电池平衡管理、电池控制单元、数据采集系统和保护电路组成,确保电池系统安全高效运行,延长电池的使用寿命并

提高电动汽车的整体性能。其中, 从板单元作为 BMS 的哨兵, 实施监控电池的电压、温度等信息以及电池模组的电压、温度信息; 高压管理单元负责对电池包的电池总压、母线总压测量; 电压采集一般由电池采样芯片和电压传感器完成; 温度采集通常使用线式和贴片热敏电阻; 电流采集主要采集电池模组的充电电流、放电电流, 由霍尔传感器或者分流器采集。从板通过与 BMS 主控单元的通信, 实时传输每个单体电池的状态数据, 包括电压、温度等信息, 确保 BMS 能够做出最合适的决策<sup>[26-28]</sup>。BMS 工作流程如图 2 所示。



图 2 电池管理系统工作流程

Fig. 2 Battery management system workflow

### 1.2 网络模型 Informer

Informer 模型在 Transformer 模型的基础上改进其原有的注意力机制, 引入性能更为突出的多头稀疏自注意力 (multi probspare self attention, MPPSA) 机制 (具有强大的表达能力和适应性, 在各种数据分析任务中都具有良好的优势)<sup>[29]</sup>。鉴于模型 Informer 在长时间序列预测任务的优越表现, 本文采用 Informer 网络作为预测模型, 其结构如图 3 所示。

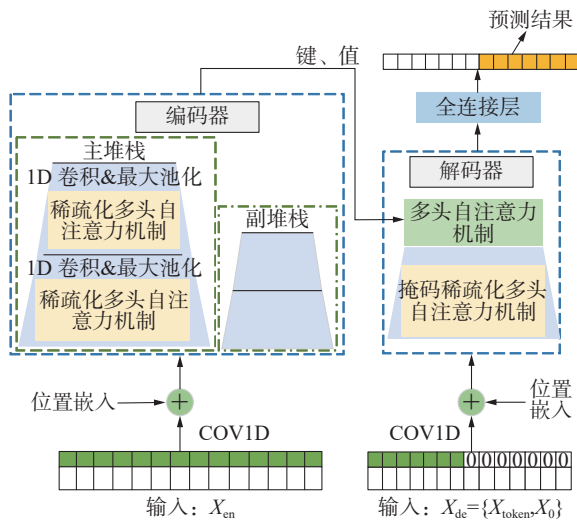


图 3 Informer 网络结构

Fig. 3 Informer network architecture

### 1.3 SDAE-DCPInformer 框架

采用堆叠降噪自编码器 (stacked denosing autoencoder, SDAE) 对原始数据中的初始电压、电流和温度数据进行清洗, 得到修复后的完整数据, 为估算模型提供优质数据。采用 DCP 技术对 Informer 模型中的 MPPSA 机制以及多头自注意力 (multi

head self attention, MHSA) 机制实施剪枝操作, 实现 Informer 模型的轻量化, 组成模型 DCPInformer。再次, 将清洗后的优质数据与 DCPInformer 模型相结合以实现获取正常工作阶段荷电状态 SOC 变化情况的目标。最后基于 SOC 的变化趋势能够反应实际电池最大容量的变化, 将工作阶段的 SOC 变化曲线作为模型 DCPInformer 的输入条件, 分别实现充电阶段和放电阶段健康状态 SOH 的估计, 实现 SOC 和 SOH 的同步输出。

## 2 SDAE 数据清洗

### 2.1 堆叠降噪自编码器原理

SDAE 采用多层降噪自编码器结构向输入数据随机添加噪声, 进而学习受损数据的特征, 具有强大的数据恢复能力<sup>[30]</sup>。数据清洗如图 4 所示。




图 4 数据清洗

Fig. 4 Data cleaning

首先设置好相应的噪声覆盖率添加到数据  $X$  中获取样本  $\tilde{X}$ , 然后经过 Sigmoid 函数编码得到输出  $H_{DE}$ :

$$H_{DE} = \sigma_{DAE} (W_{encoder} \tilde{x}_n + b_{encoder})$$

式中:  $W_{encoder}$  是权重矩阵,  $b_{encoder}$  是偏置矩阵,  $\sigma_{DAE}$  为 Sigmoid 函数。

$H_{DE}$  经过权重矩阵、偏置矩阵和 Sigmoid 函数的解码获得最终的样本  $\hat{X}$ :

$$\hat{X} = \sigma_{DAE} (W_{decoder} H_{DE} + b_{decoder})$$

SDAE 中的编码和解码结构如图 5 所示。

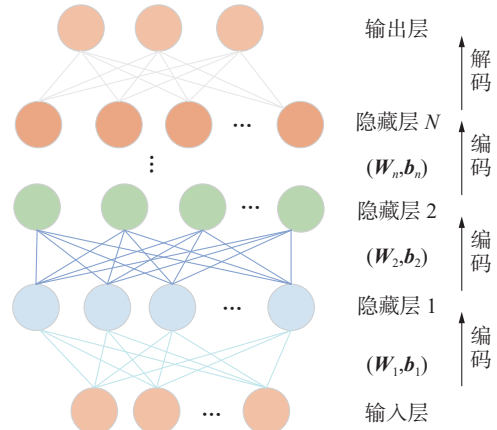


图 5 SDAE 中的编码和解码结构

Fig. 5 Encoding and decoding structures in SDAE

### 2.2 修复数据

传感器需要采集数据以便系统分析动力电池的 SOC 和 SOH。但由于环境条件、外部扰动和传感器故障等因素的影响,导致采集的数据中出现异常数据、空缺数据、噪声数据,制约着电池管理系统 BMS 精确估计 SOC 和 SOH,异常和空缺数据示意如图 6 所示。




图 6 异常和空缺数据示意

Fig. 6 Schematic diagram of abnormal and vacancy data

因为 SDAE 能够有效修复异常数据集中不符合正常分布的孤立点数据以及填充空缺数据,所以本节使用 SDAE 清洗电压、电流、温度数据。

为提高 SDAE 数据清洗的能力,采用贝叶斯算法(Bayesian optimization, BO)对 SDAE 的隐藏层层数、每层的节点数、学习率、噪声覆盖率 4 个超参数进行寻优。将 SDAE 的重构误差作为适应度值,不断训练得到重构效果最好的 SDAE 超参数。最后采用 5 折交叉验证方法评估模型性能,得到最优 SDAE 数据清洗模型。本文设置的超参数寻优范围如表 1 所示。

表 1 超参数寻优范围

Table 1 Hyperparameter optimization range

超参数	超参数含义	取值范围
Number of hidden layers	隐藏层层数	[2,6]
Number of nodes	节点数	[10,100]
Learning rate	学习率	[0.001,0.01]
Noise coverage rate	噪声覆盖率	[0,1]

本节以牛津大学电池数据集和北京理工大学 Nature 电池数据集进行实验,将数据集划分为训练集和测试集,且相应比例为 7:3。设置输入层和输出层的节点数为 100,即输入的数据量为 100。贝叶斯优化 SDAE 参数适应度曲线如图 7 所示。

由图 7 可知,当迭代次数达到 200 次时适应度值趋于稳定,最终得到 SDAE 模型的最优超参数,如表 2 所示。




图 7 贝叶斯优化 SDAE 参数适应度曲线

Fig. 7 Bayesian optimization of SDAE parameter fitness curves

表 2 SDAE 模型最优超参数

Table 2 Optimal hyperparameters of the SDAE model

超参数	超参数含义	取值
Number of hidden layers	隐藏层层数	4
First hidden layer node	第1层节点数	50
Second hidden layer nodes	第2层节点数	65
Third hidden layer node	第3层节点数	30
Fourth hidden layer nodes	第4层节点数	50
Learning rate	学习率	0.01
Noise coverage rate	噪声覆盖率	0.3

SDAE 对电压的清洗效果如图 8 所示。




图 8 电压清洗效果

Fig. 8 Voltage cleaning effect diagram

综上所述,SDAE 为准确估算电动汽车动力电池的荷电状态 SOC 和健康状态 SOH 提供了高质量的数据支撑。

### 3 对 Informer 模型进行剪枝优化

Informer 模型中 MPPSA 机制和 MHSA 机制的头数通常需要人为设定,过多的头数会导致模型计算复杂度增加,影响预测准确度。针对以上问题,本文采用 DCP 技术对 Informer 模型进行改进优化。

DCP 是一种基于深度神经网络的动态剪枝技

术, 相比其他剪枝技术, 它可以在训练过程中实时地剪除神经网络中的通道, 无需额外的分散微调剪枝过程, 减少模型的参数数量和计算量, 同时保持模型的性能<sup>[31]</sup>。主要方法是通过设计智能通道门以随机的关闭每个通道, 从而可以观察到条件准确率变化进而最终决定剪枝冗余的通道。动态通道剪枝结构如图 9 所示。

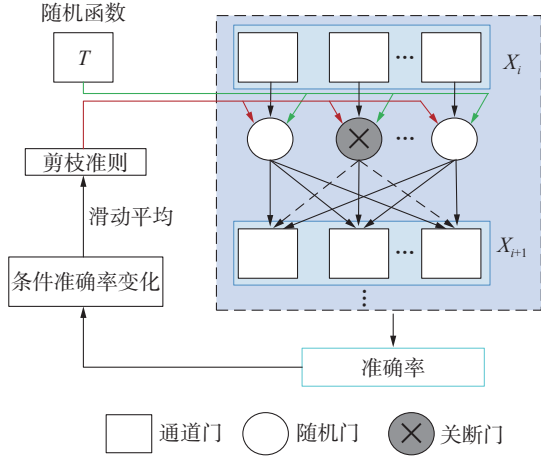


图 9 DCP 结构  
Fig. 9 Structure of DCP

### 3.1 剔除冗余多头稀疏自注意力

MPPSA 机制结合了多头注意力和稀疏注意力的优势, 降低了长序列数据的复杂度。但 MPPSA 中的部分稀疏注意力提取输入序列特征对最终预测任务的作用微乎其微, 甚至反过来降低模型的预测精度, 并且导致较高的计算成本, 占用较高的内存, 增加存储负担。在提取数据特征时, Informer 模型中冗余多头稀疏自注意力的作用如图 10 所示。




图 10 Informer 模型中冗余 MPPSA 示意  
Fig. 10 Schematic of redundant MPPSA in the Informer model

MPPSA 机制用公式表示为

$$[\bar{Q}, K, V] = f[X_1, X_2, \dots, X_n]$$

式中:  $f$  为对输入数据  $X$  进行线性变换,  $\bar{Q}$ 、 $K$ 、 $V$  分别为稀疏查询向量、键向量、值向量。

$$\text{head} = \text{Attention}(\bar{Q}, K, V) = \text{Softmax} \left( \frac{\bar{Q}K^T}{\sqrt{dk}} \right) V$$

式中:  $\text{head}$  为单个稀疏注意力,  $\text{Softmax}$  为激活函数,  $d_k$  为稀疏查询向量  $\bar{Q}$  和键向量  $K$  的维度。

$$\text{Multihead}(\bar{Q}, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h, \text{head}_g)W^0$$

式中:  $\text{Multihead}$  为多头稀疏注意力,  $\text{Concat}$  为将多个单头稀疏注意力拼接的操作,  $\text{head}_g$  为 MPPSA 中冗余稀疏注意力。

冗余稀疏注意力对估算准确率的影响为

$$a_n = F[\text{Concat}(\text{head}_1, \text{head}_2, \text{head}_g, \dots, \text{head}_h)W^0]$$

式中:  $a_n$  为最终预测任务的准确度,  $F$  为包含特征融合以及输出准确度操作,  $W^0$  为参数矩阵。

针对 Informer 模型中存在稀疏注意力冗余的问题, 本小节采用 DCP 技术, 依据智能通道门和条件准确率的变化对 Informer 模型内部 MPPSA 机制中的冗余稀疏注意力进行剪枝, 如图 11 所示。

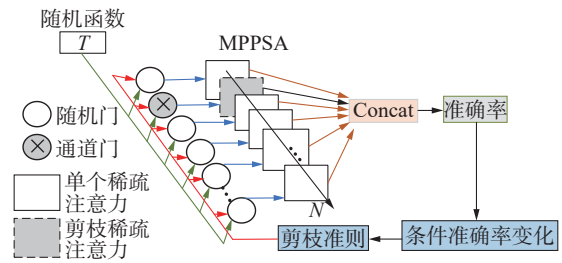


图 11 DCP 剪枝 MPPSA  
Fig. 11 DCP pruning MPPSA

首先随机函数按照设置随机关断智能通道门中的通道, 进而关断 MPPSA 机制中部分稀疏注意力。对此层的 MPPSA 增加智能通道门, 用公式表示为

$$\text{Multihead} = F(g \otimes \text{head}, \{W_i\})$$

式中:  $\otimes$  为通道关断, 由参数  $g = (g_1, g_2, \dots, g_c) \in \{0, 1\}$  决定;  $c$  与输入通道  $X$  同纬度, 给参数  $g$  赋予 0 值即可关断每个通道;  $\{W_i\}$  为网络参数;  $F$  为执行函数。

其次将未关断的稀疏自注意力进行拼接, 依据初始准确率和条件准确率的变化以及剪枝准则对部分稀疏注意力机制进行剪枝, 用公式表示为

$$a_n = \xi a_{n-1} + (1 - \xi) f_n(X_n, Y_n, T(n))$$

式中:  $a_n$  为初始准确率,  $a_0 = 0$ ;  $\xi$  为指数滑动平均;  $T(n)$  为第  $n$  批的随机关断函数;  $f_n(X_n, Y_n, T(n))$  为第  $n$  批的准确率。

$$b_{s_{im}} = \xi' b_{s_{im-1}} + (1 - \xi') f_{s_{im}}(X_{s_{im}}, Y_{s_{im}}, T(s_{im}))$$

$$b_{s_0} = 0, \xi' = \xi^{\frac{1}{P(g_i=0)}}$$

式中:  $b_{s_{im}}$  为  $g_i = 0$  时的精确度, 即关断通道后的准确率  $f_{s_{im}}(X_{s_{im}}, Y_{s_{im}}, T(s_{im}))$  为关断第  $m$  通道的准确率,  $m \in n$ 。

$$S_n(g_i) = a_n - b_{s_{im}}$$

式中  $S_n(g_i)$  为条件准确率变化。当达到  $S_n(g_i) \leq 0$

时, 即  $a_n \leq b_{sim}$  条件时, 依据剪枝准则减少 MPPSA 机制中稀疏注意力头的个数, 在压缩模型, 减少计算量和运算量的同时, 仍能有效捕捉输入序列中的信息, 保持模型的高效性。改进后的 MPPSA 提取输入数据特征示意如图 12 所示。




图 12 改进后 MPPSA 提取输入数据特征示意  
Fig. 12 Schematic diagram of input data features extracted by the improved MPPSA

本文将 DCP 技术嵌入至 Informer 模型编码器和解码器中相应的稀疏自注意力通道, 以便更好地处理编码器和解码器的长输入数据, 更快地进行训练和推断, DCP 嵌入位置如图 13 所示。

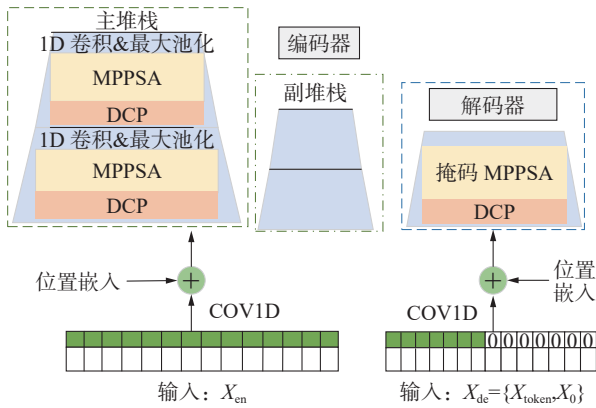


图 13 DCP 嵌入位置  
Fig. 13 DCP embedding locations

最终本文提出的 DCP 技术作用于 MPPSA 表示为

$$f_{DCPMPPSA}(\bar{Q}, K, V, g_c) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n, g_c)W^0$$

$$S_n(g_i) = a_n - b_{sim} \leq 0$$

式中:  $f_{DCPMPPSA}$  为动态剪枝多头稀疏注意力操作,  $g_c$  控制通道关断,  $S_n(g_i) \leq 0$  为执行条件。

### 3.2 优化多头自注意力机制

Informer 模型内部的 MHSA 采用多个缩放点积计算方式的注意力头, 融合来自编码器和解码器输入数据的特征  $[H_1, H_2, \dots, H_n]$ , 最终经全连接层输出结果。但 MHSA 与 MPPSA 存在相同的问题, 即冗余注意力机制仍然存在。冗余注意力机制一方面占据一定的存储空间, 影响模型的运算效率; 另一方面导致特征融合不充分, 影响模型的预测准确度。

Informer 模型中冗余多头自注意力作用示意如图 14 所示。

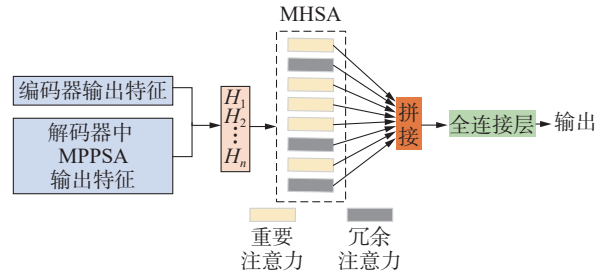


图 14 冗余多头自注意力作用示意  
Fig. 14 Schematic diagram of the redundant multiple self-attention

冗余多头注意力作用机制的计算公式为

$$[Q, K, V] = f[H_1, H_2, \dots, H_n]$$

$$\text{head} = \text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{dk}}\right)V$$

$$\text{Multihead}(Q, K, V) =$$

$$\text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h, \text{head}_g)W^0$$

式中:  $Q$  为查询向量,  $[H_1, H_2, \dots, H_n]$  为编码器和解码器输出的特征, Multihead 为多头注意力。

冗余多头注意力对预测准确率的影响为

$$a_n = F_c[\text{Multihead}(Q, K, V)] =$$

$$F_c[\text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_g, \text{head}_n)W^0]$$

式中:  $F_c$  为全连接层,  $\text{head}_g$  为多头注意力中冗余注意力。

针对 Informer 模型同时也存在着 MHSA 冗余的问题, 本小节采用 DCP 技术对 Informer 模型中的 MHSA 中的冗余自注意力进行剪枝, 依据智能通道门和条件准确率的变化, 有选择性的剪枝冗余的自注意力, 减少多头自注意力机制中自注意力头的个数, 增强融合编码器和解码器两部分的输出特征能力, DCP 剪枝 MHSA 如图 15 所示。

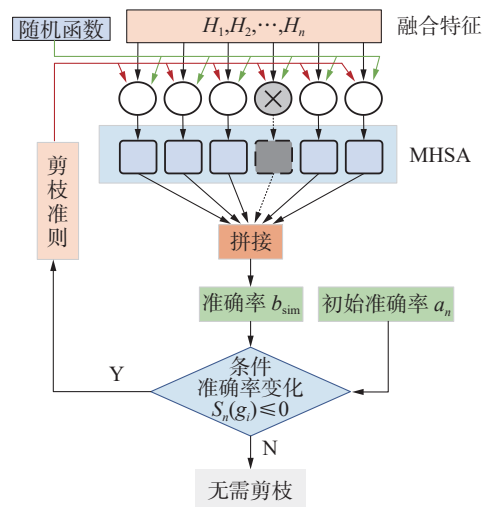


图 15 DCP 剪枝 MHSA  
Fig. 15 DCP pruning MHSA

剪枝后 MHSA 融合编码器和解码器中 MPPSA 输出特征并最终输出预测结果, 改进后 MHSA 融

合特征示意如图 16 所示。




图 16 改进后 MHSA 融合特征示意

Fig. 16 Schematic of the improved MHSA fusion features

本小节将 DCP 技术嵌入至 Informer 模型解码器中的 MHSA, 以便更好地融合来自编码器和解码器中的输出特征, DCP 嵌入位置如图 17 所示。

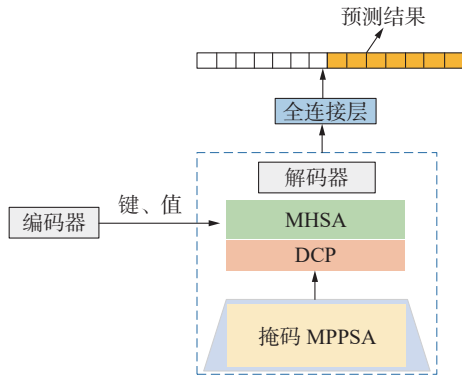


图 17 DCP 嵌入位置

Fig. 17 DCP embedding locations

最终本文提出的 DCP 技术作用于 MHSA 的

公式表示为

$$f_{\text{DCPMHSA}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}, g_c) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n, g_c) \mathbf{W}^0$$

$$S_n(g_i) = a_n - b_{\text{sim}} \leq 0$$

式中:  $f_{\text{DCPMHSA}}$  为动态剪枝多头自注意力操作,  $g_c$  控制通道关断,  $S_n(g_i) \leq 0$  为执行条件。

### 3.3 改进后的 Informer 模型

传统 Informer 模型的计算方式简化为

$$Y[y_1, y_2, \dots, y_n] = f_{\text{Informer}}(\mathbf{X}[x_1, x_2, \dots, x_n])$$

改进之后的 DCPInformer 模型的计算方式简化为

$$\mathbf{H}[h_1, h_2, \dots, h_n] = f_{\text{DCPMPPSA}}(\mathbf{X}[x_1, x_2, \dots, x_n])$$

$$Y[y_1, y_2, \dots, y_n] = f_{\text{DCPMHSA}}(\mathbf{H}[h_1, h_2, \dots, h_n])$$

$$S_n(g_i) = a_n - b_{\text{sim}} \leq 0$$

$$Y[y_1, y_2, \dots, y_n] = f_{\text{DCPInformer}}(\mathbf{X}[x_1, x_2, \dots, x_n])$$

当条件变化率准确率变化值  $S_n(g_i) \leq 0$  时, 即当  $a_n \leq b_{\text{sim}}$  时, 意味着对稀疏注意力或者常规注意力实施随机关断操作之后模型的准确率比初始准确率提高, 此时则需要根据剪枝准则对 Informer 模型进行剪枝。

改进后的 DCPInformer 模型结构如图 18 所示。

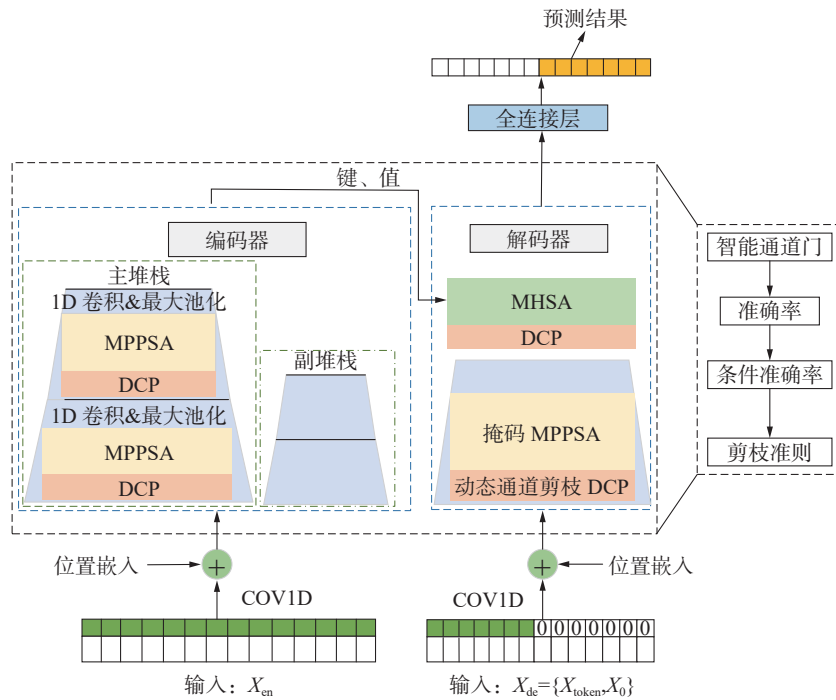


图 18 改进后的 DCPInformer 模型

Fig. 18 Improved DCPInformer model

采用 DCP 技术对 Informer 模型进行压缩, 主要体现在对模型中 MPPSA 机制以及 MHSA 机制中冗余自注意力机制进行剪枝, 从而实现结构和

参数量方面的压缩。相比于原有 Informer 模型, DCPInformer 模型无需人工手动设计编码器和解码器中 MPPSA 和 MHSA 的头数, 能够根据模型

估算 SOC 和 SOH 准确度自适应的调节模型的参数, 避免不必要的重复设定参数训练, 也有助于得到最优的估算效果。

### 3.4 SDAE-DCPInformer 结构

SDAE-DCPInformer 网络模型结构如图 19 所示。首先采用 SDAE 清洗传感器获取到的初始电压、电流以及温度数据, 清洗后的数据输入 DCPInformer 模型的编码器和解码器, 最终得到预测

结果。

综上所述, 本文构建了 SDAE-DCPInformer 预测模型, 其能够将动力电池工作阶段的荷电状态 SOC 和健康状态 SOH 数据传输至电动汽车电池管理系统 (BMS), 具有促进 BMS 改进升级, 促进后台 SOC 和 SOH 数据的更新, 协助电动汽车用户更好管理车辆续航里程的现实意义。实际流程如图 20 所示。

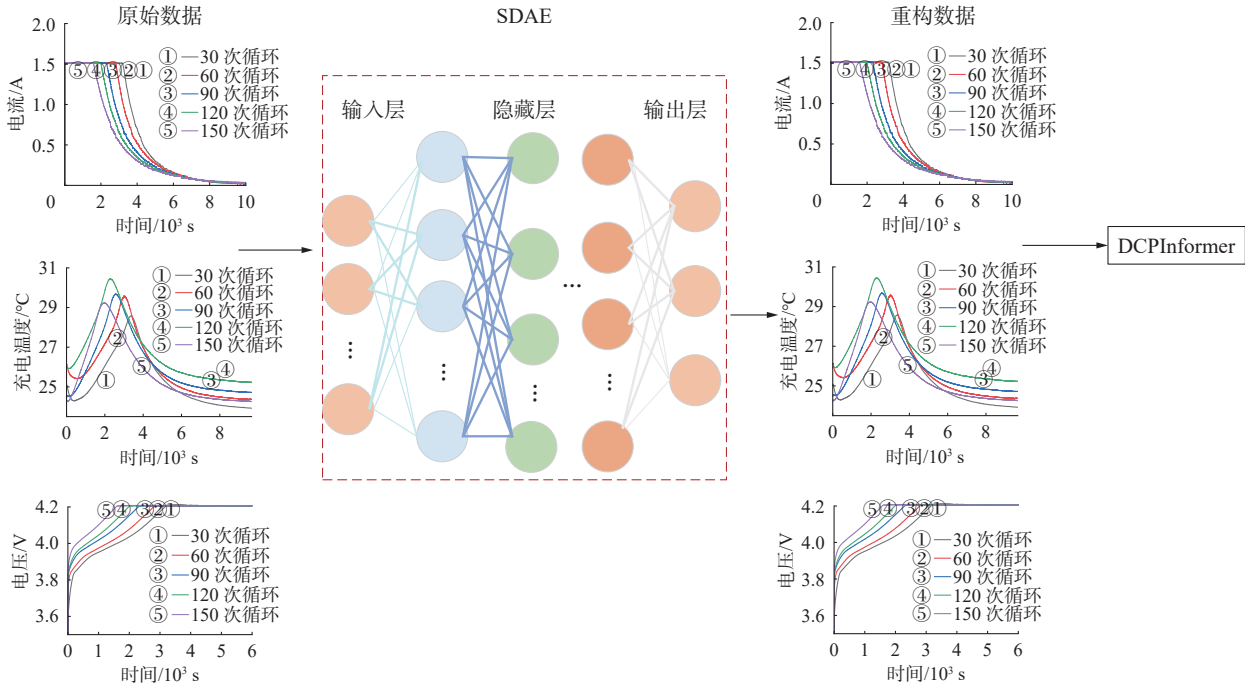


图 19 SDAE-DCPInformer 网络模型结构

Fig. 19 SDAE-DCPInformer network model structure

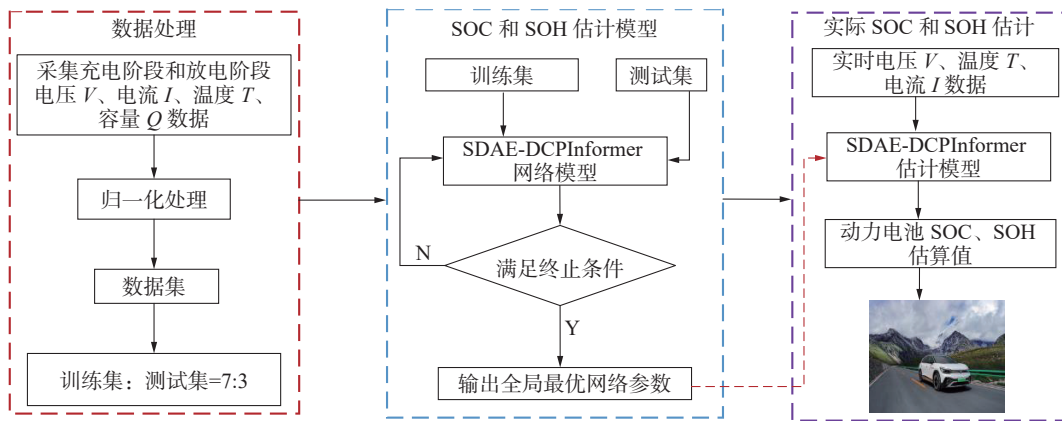


图 20 实际流程

Fig. 20 Actual flowchart

## 4 实验与分析

本节依据牛津大学电池数据集和北京理工大学 Nature 电池数据集两个数据集进行实验。对比实验为 SDAE-DCPInformer 模型与其他 4 种模型的效果对比。为了评估提出堆叠降噪自编码

器 SDAE、动态通道剪枝 DCP、Informer 3 种改进点对估计 SOC 和 SOH 的效果, 本节设置了消融实验。

### 4.1 动力电池数据集

牛津大学电池数据集是由牛津大学的研究团队开发和发布的一个数据集, 广泛用于电池状态

分析的研究。8 块磷酸铁锂电池在 40 °C 下进行循环充放电, 充电阶段以 1.48 A 的恒流电流将电压升至 4.2 V, 放电阶段以 0.74 A 的恒流将电压降至 2.7 V。数据集包含电池在不同放电和充电周期中的电压、温度、电流和容量等数据。

北京理工大学 Nature 数据集包含镍钴锰 NMC 和磷酸铁锂 LiFePO<sub>4</sub> 两种不同材料的电池数据。采用 ARBIN BT2000 电池充放电系统对两种电池进行循环充放电操作。镍钴锰 NMC 电池先以 0.3 C 的恒流将电压升至 4.2 V, 再以 2C 的恒流将电压降至 2.7 V。磷酸铁锂 LiFePO<sub>4</sub> 电池先以 1C 的恒流将电压升至 3.65 V, 再以 1C 的恒流将电压降至 2.7 V。训练集为镍钴锰电池中的 1 号和 2 号电池以及磷酸铁锂电池中的 1 号和 3 号电池, 测试集为镍钴锰电池中的 3 号电池和磷酸铁锂的 2 号电池。数据采集具体步骤如图 21 所示。



图 21 数据采集步骤

Fig. 21 Data acquisition procedures

本文采用归一化方法处理数据, 计算公式为

$$X' = \frac{X - \min(X)}{\max(X) - \min(X)}$$

为了衡量模型估算结果和真实值之间的差异, 将平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean square error, RMSE) 视为评估标准, 计算公式为

$$M_{AE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|$$

$$R_{MSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}$$

式中:  $y_i$  为预测值,  $\hat{y}_i$  为实际值,  $m$  为样本的数量。

#### 4.2 模型参数设置

估算模型中输入层和输出层节点数为 100, 运用贝叶斯优化技术确定堆叠降噪自编码器中的隐藏层中的层数为 4, 隐藏节点个数分别为 50、65、30、50, 学习率为 0.01, 噪声覆盖率为 0.3; 动态通道剪枝采用随机梯度下降 SGD 进行参数优化,

Nesterov 动量系数为 0.9, 权重衰减系数为 0.0001, 学习率为 0.1, 滑动平均设置为 0.997; Informer 模型中编码器堆叠层数为 3, 解码器堆叠层数为 2 层, 注意力头数的范围为 [4,12], 稀疏注意力稀疏程度为 10。

#### 4.3 不同温度下 SDAE-DCPInformer 估计结果

本节在两个电池数据集上进行实验, 评估 SDAE-DCPInformer 模型在不同温度条件下估算电池 SOC 和 SOH 的能力。

##### 4.3.1 20 °C 温度下模型估算结果

基于北京理工大学中镍钴锰电池数据验证模型效果, 如表 3 所示。

表 3 20 °C 温度下模型估算结果  
Table 3 Result of model estimated at 20 °C %

型号	状态	MAE			RMSE		
		最小	最大	平均	最小	最大	平均
Cell3	SOC	0.22	0.41	0.25	0.29	0.5	0.35
	SOH	0.34	0.63	0.55	0.53	0.71	0.61

##### 4.3.2 40 °C 下模型的估算结果

基于牛津大学电池数据验证模型效果, 如表 4 所示。

表 4 40 °C 温度下模型估算结果  
Table 4 Result of model estimated at 40 °C %

型号	状态	MAE			RMSE		
		最小	最大	平均	最小	最大	平均
Cell4	SOC	0.21	0.4	0.26	0.28	0.5	0.38
	SOH	0.36	0.62	0.51	0.53	0.7	0.64
Cell8	SOC	0.23	0.36	0.3	0.31	0.42	0.38
	SOH	0.45	0.63	0.57	0.53	0.68	0.64

##### 4.3.3 45 °C 温度下模型的估算结果

基于北京理工 Nature 电池数据集中电池 Gotion IFP20100140A 开展实验, 评价指标为 MAE 和 RMSE, 所提模型评估 SOC 和 SOH 的结果如表 5 所示。

表 5 45 °C 温度下模型估计结果  
Table 5 Result of model estimated at 45 °C %

型号	状态	MAE			RMSE		
		最小	最大	平均	最小	最大	平均
Cell2	SOC	0.27	0.34	0.28	0.33	0.5	0.36
	SOH	0.4	0.58	0.48	0.5	0.62	0.57

牛津大学以及北京理工大学数据集中镍钴锰电池和磷酸铁锂电池数据均是分开训练的。实际应用时不同温度下采集到的电池电压、电流、温

度变化趋势是不同的,因此不能混合在一起训练,混合训练会导致模型估算精度降低。不同温度下的网络参数差异主要在于 Informer 模型的编码器和解码器中的 MPPSA 和 MHSA 中的头数不同,而本文中提出的 DCP 能够根据模型的估算精度自适应的调整模型的参数,进而得出最优模型参数。不同温度下 Informer 模型的解码器中 MPPSA 和 MHSA 的头数如表 6 所示。

表 6 不同温度下模型的参数

Table 6 Model parameter under different temperature

温度/°C	编码器		解码器	
	MPPSA头数	MPPSA的头数	MHSA头数	MHSA头数
20	8	5	6	6
40	10	6	6	6
45	11	7	5	5

从 SDAE-DCPInformer 模型估算 SOC 和 SOH 的表现上来看,所提模型在不同温度下的动

表 7 不同剪枝率下模型性能表现

Table 7 Model performance under different pruning rates

剪枝率/%	SOC		SOH		参数量/10 <sup>6</sup>	计算时间/s
	MAE/%	RMSE/%	MAE/%	RMSE/%		
0	0.432	0.546	0.625	0.763	14.193 539	1 440
10	0.415	0.518	0.617	0.749	10.384 792	1 200
25	0.381	0.492	0.605	0.711	8.346 482	984
30	0.356	0.468	0.584	0.670	6.278 437	744
40	0.325	0.426	0.563	0.648	5.748 249	606
50	0.374	0.469	0.600	0.684	4.972 784	510

从表 7 可以看出,本文提出的 DCP 技术在不同的剪枝率情况下估算 SOC 与 SOH 的准确度不同,但均比初始 Informer 模型有所提升。虽然随着剪枝率的提高,参数量、计算时间以及内存消耗也不断的减少,但过高的剪枝率会影响 SOC 以及 SOH 的估算准确度。结合模型参数量、计算时间、内存消耗以及 SOC 和 SOH 估算准确度情况,最终确定模型剪枝率为 40% 时符合预期效果。

#### 4.4.2 SDAE-DCPInformer 与传统模型 Transformer、GRU、LSTM、ELM 对比

以牛津大学退化电池数据和北京理工大学 Nature 电池数据集为基础,将提出的 SDAE-DCPInformer 模型在估算电池 SOC 和 SOH 准确度方面与文献 [19] 中 Transformer、文献 [16] 中 LSTM、文献 [17] 中 GRU、文献 [15] 中 ELM 4 种模型进行对比。5 种模型在训练 SOC 过程中的 MAE 变化情况如图 22 所示,在训练 SOH 过程中的 MAE 变化情况如图 23 所示。

力电池状态的估算误差较小,具有良好的估算能力。

#### 4.4 对比实验

模型性能与关键参数 DCP 的剪枝率是密切相关的,参数的变化会显著影响模型的性能和稳定性。此外,主流的时间序列预测模型 Transformer、LSTM、GRU、ELM 在电池状态估算领域中表现出优异的性能。不同充放电周期下模型性能更能体现模型的泛化性以及适应性。为了凸显所提方法的独特优势,因此将对比实验分为不同剪枝率下模型的性能比较、与传统模型 Transformer、GRU、LSTM、ELM 对比、不同充放电周期下模型性能对比 3 个部分。

##### 4.4.1 不同剪枝率下模型的性能比较

为了验证动态通道剪枝 DCP 技术对 Informer 模型不同剪枝率的有效性,本小节将探索模型在剪枝率为 0% (不剪枝)、10%、25%、30%、40%、50% 时估计 SOC 和 SOH 的表现,如表 7 所示。




图 22 SOC 训练过程中 MAE 变化情况

Fig. 22 Changes in MAE during the SOC training process




图 23 SOH 训练过程中 MAE 变化情况

Fig. 23 Changes in MAE during the SOH training process

从图 22 和图 23 中可以看出在训练过程中, SDAE-DCPInformer 模型估算 SOC 和 SOH 的平均绝对误差值最先达到收敛且误差值最小。

各模型 Cell14 中 SOC 的估算结果如图 24 所示。

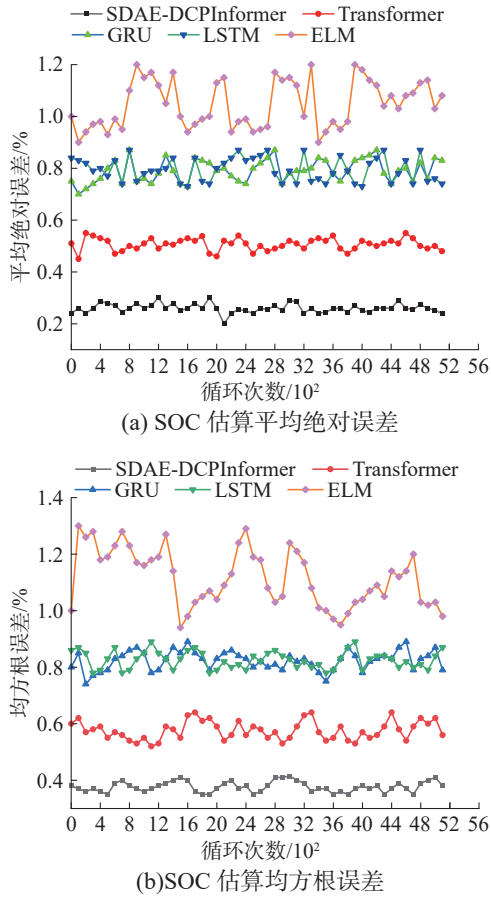


图 24 各模型 Cell4 中 SOC 估算结果  
Fig. 24 SOC estimation results in each model Cell4

从图 24 中可以看出本文模型 SDAE-DCPInformer 在牛津大学电池数据集中的 4 号电池 SOC 估算的 MAE 以及 RMSE 的值均低于 Transformer、GRU、LSTM、ELM 模型, 并且误差浮动率

较低, 表现得更加稳定。

各模型 Cell14 中 SOH 的估算结果如图 25 所示。

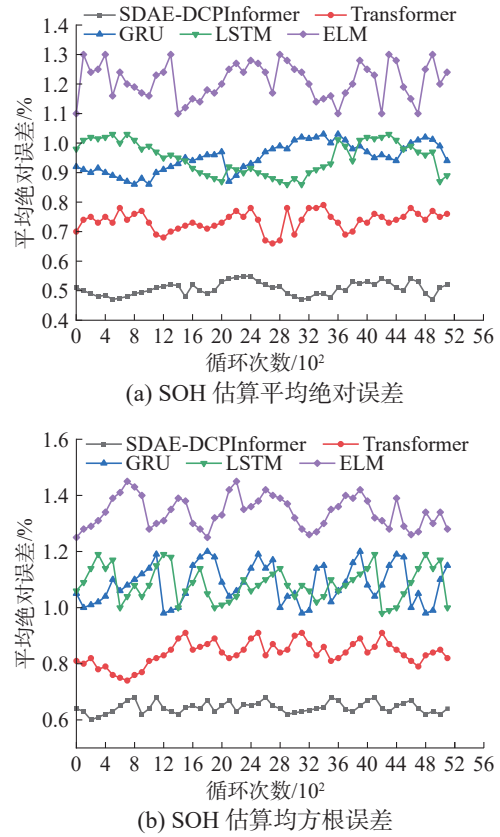


图 25 各模型 Cell4 中 SOH 估算结果  
Fig. 25 SOH estimation results in each model Cell4

从图 25 中可以看出本文模型 SDAE-DCPInformer 在牛津大学电池数据中 4 号电池 SOH 估算 MAE 以及 RMSE 的值均低于 Transformer、GRU、LSTM、ELM 模型, 且能保持较好的稳定性。

SDAE-DCPInformer 模型与 Transformer 等 4 种模型在估算精度、模型参数量等方面的性能对比如表 8 所示。

表 8 SDAE-DCPInformer 模型与各模型性能对比  
Table 8 Comparison of the performance of the SDAE-DCPInformer model with each model

模型	SOC		SOH		计算时间/s	参数量/10 <sup>6</sup>
	MAE/%	RMSE/%	MAE/%	RMSE/%		
ELM	1.05	1.24	1.15	1.27	21 060	15.545 345
LSTM	0.77	0.84	0.94	1.11	1 974	14.954 737
GRU	0.75	0.80	0.92	1.05	1 824	14.845 784
Transformer	0.50	0.60	0.72	0.81	1 518	10.467 368
SDAE-DCPInformer	0.25	0.38	0.51	0.64	906	6.387 758

综上所述, 相比 Transformer、GRU、LSTM、ELM 模型, 模型 SDAE-DCPInformer 估算 SOC 和

SOH 的精度高, 模型复杂度较低, 在估算 SOC 和 SOH 方面具有显著优势。

### 4.4.3 不同充放电周期下模型性能对比

模型在不同充放电周期下的性能也极其重要。以 Cell4 电池为例,依次给出了电池循环次数在 200 次、1 000 次、5 000 次时的 SOC 估算结果。如图 26 所示,当循环次数为 200 次时,本文提出的 SDAE-DCPInformer 估算的 SOC MAE 为 0.28%, RMSE 为 0.42%;当循环次数为 1 000 次时, SOC MAE 为 0.26%, RMSE 为 0.39%;当循环次数为 5 000 次时, SOC MAE 为 0.3%, RMSE 为 0.44%。




图 26 不同循环次数下 SOC 估算效果

Fig. 26 Effect of SOC estimation with different number of cycles

SDAE-DCPInformer 模型跟踪电池整个循环过程中的健康状态时, SOH 估算值与实际值对比

如图 27 所示。




图 27 SOH 估算值与实际值对比

Fig. 27 Comparison of estimated SOH values with actual values

从以上对比实验的分析上可以得出以下结论: 1) 当 Informer 模型剪枝率为 40% 时估算效果较好; 2) 模型 SDAE-DCPInformer 在估算准确度, 复杂度方面全部优于其他 4 种模型; 3) 模型能够跟踪不同充放电周期的 SOC 和 SOH, 适应性强。对比实验的结论验证了模型估算 SOC 和 SOH 的有效性, 为在不同场景下选择模型的参数也提供了支持。

### 4.5 消融实验

本文提出 3 条改进: 采用堆叠降噪编码器清洗数据, 提出 DCP 技术对模型进行压缩, 基于 Informer 在长时间序列预测的优越表现。将 Informer 模型作为本次预测的主要模型进行消融实验, 实验结果如表 9 所示。

从表 9 实验结果得出, 第 1 组实验增加数据清洗操作, 在异常数据、噪声数据、噪声数据降低的情况下, Cell4 和 Cell3 电池的 SOC 估算和 SOH 估算 MAE 和 RMSE 均降低。第 2 组实验采用动态通道剪枝 DCP 技术对预测模型进行压缩, 提高运算效率的情况下, Cell4 和 Cell3 电池的 SOC 估算和 SOH 估算 MAE 和 RMSE 同样降低。第 3 组使用 Informer 估算模型, 效果也得到提升。其他组 2 个模块和 3 个模块互相结合的效果进一步提高。

综上所述, 从文章中不同温度下模型估算结果、不同剪枝率下 Informer 模型性能、与主流的时间序列预测模型 Transformer 等模型估算效果的对比以及消融实验中各个改进点的效果上可以看出, 实验结果的优越性主要体现在有效改善数据质量, 减少模型时间和空间上的复杂度, 提升荷电状态 SOC 和健康状态 SOH 的估算准确度, 利于实际应用。

表 9 实验结果  
Table 9 Experiments results

%

算法模型	SDAE	DCP	Informer	Cell4				Cell3			
				SOC		SOH		SOC		SOH	
				MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
Transformer				0.50	0.62	0.70	0.81	0.54	0.60	0.68	0.79
SDAE-Transformer	√			0.45	0.57	0.66	0.75	0.48	0.58	0.65	0.77
DCPTransformer		√		0.41	0.53	0.61	0.73	0.40	0.54	0.62	0.74
Informer			√	0.42	0.54	0.62	0.76	0.44	0.53	0.63	0.75
SDAE-DCPTransformer	√	√		0.30	0.42	0.55	0.64	0.32	0.47	0.57	0.65
SDAE-Informer	√		√	0.37	0.50	0.59	0.69	0.35	0.52	0.57	0.70
DCPInformer		√	√	0.32	0.46	0.56	0.64	0.31	0.43	0.57	0.63
SDAE-DCPInformer	√	√	√	0.25	0.38	0.50	0.64	0.27	0.39	0.47	0.60

## 5 结束语

本文提出了一种能够精确估算电动汽车动力电池 SOC 和 SOH 的 SDAE-DCPInformer 模型, 充分挖掘电压、电流、温度蕴含的信息, 估算电池在充电阶段和放电阶段的 SOC 和 SOH 变化情况。在牛津大学和北京理工大学 Nature 电池数据集上的实验结果表明, 本文提出的 SDAE-DCPInformer 模型预测 SOC 和 SOH 的效果能够用于各种工作环境的估算, 拥有较好的泛化性和稳定性。本研究有助于提升电动汽车电池的安全性并且满足用户出行需求。在未来, 深度考虑电动汽车用户驾驶习惯、行驶路况、新型高质量电池等因素有益于电池管理系统 BMS 升级。

## 参考文献:

- [1] 黄钰期, 梅盼, 陈晓济, 等. 基于 CFD 分析的电动汽车电池包加热方法[J]. 浙江大学学报(工学版), 2019, 53(2): 207-213,219.  
HUANG Yuqi, MEI Pan, CHEN Xiaoji, et al. Heating strategy for electric vehicular battery pack based on CFD analysis[J]. Journal of Zhejiang university (engineering science edition), 2019, 53(2): 207-213,219.
- [2] 杨续来, 袁帅帅, 杨文静, 等. 锂离子动力电池能量密度特性研究进展[J]. 机械工程学报, 2023, 59(6): 239-254.  
YANG Xulai, YUAN Shuaishuai, YANG Wenjing, et al. Research progress on energy density of Li-ion batteries for EVs[J]. Journal of mechanical engineering, 2023, 59(6): 239-254.
- [3] 闫啸宇, 周思达, 卢宇, 等. 锂离子电池容量衰退机理与影响因素[J]. 北京航空航天大学学报, 2023, 49(6): 1402-1413.  
YAN Xiaoyu, ZHOU Sida, LU Yu, et al. Degradation mechanism and influencing factors on lithium-ion batteries[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(6): 1402-1413.
- [4] 张青松, 赵启臣. 过充循环对锂离子电池老化及安全性影响[J]. 高电压技术, 2020, 46(10): 3390-3397.  
ZHANG Qingsong, ZHAO Qichen. Effects of over-charge cycling on the aging and safety of lithium ion batteries[J]. High voltage engineering, 2020, 46(10): 3390-3397.
- [5] 郭斌, 刘新华, 何榕, 等. 锂离子电池性能衰减与热失控机制研究进展[J]. 稀有金属, 2024, 48(2): 225-239.  
GUO Bin, LIU Xinhua, HE Rong, et al. Advances on mechanism of degradation and thermal runaway of lithium-ion batteries[J]. Chinese journal of rare metals, 2024, 48(2): 225-239.
- [6] KUMAR R R, BHARATIRAJA C, UDHAYAKUMAR K, et al. Advances in batteries, battery modeling, battery management system, battery thermal management, SOC, SOH, and charge/discharge characteristics in EV applications[J]. IEEE access, 2023, 11: 105761-105809.
- [7] SYLVESTRIN G R, SCHERER H F, HIDEO ANDO JUNIOR O. Hardware and software development of an open source battery management system[J]. IEEE Latin America transactions, 2021, 19(7): 1153-1163.
- [8] THANGAVEL S, MOHANRAJ D, GIRIJAPRASANNA T, et al. A comprehensive review on electric vehicle: battery management system, charging station, traction motors[J]. IEEE access, 2023, 11: 20994-21019.
- [9] HUANG Zexin, BEST M, KNOWLES J, et al. Adaptive piecewise equivalent circuit model with SOC/SOH estimation based on extended Kalman filter[J]. IEEE transactions on energy conversion, 2023, 38(2): 959-970.

- [10] 赵光财, 林名强, 戴厚德, 等. 一种锂电池 SOH 估计的 KNN-马尔科夫修正策略[J]. 自动化学报, 2021, 47(2): 453–463.  
ZHAO Guangcai, LIN Mingqiang, DAI Houde, et al. A modified strategy using the KNN-Markov chain for SOH estimation of lithium batteries[J]. Acta automatica sinica, 2021, 47(2): 453–463.
- [11] SHEN Ping, OUYANG Minggao, LU Languang, et al. The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles[J]. IEEE transactions on vehicular technology, 2018, 67(1): 92–103.
- [12] 蔡涛, 张钊诚, 袁奥特, 等. 锂离子电池储能安全管理中的机器学习方法综述[J]. 电力系统保护与控制, 2022, 50(24): 178–187.  
CAI Tao, ZHANG Zhaocheng, YUAN Aote, et al. Review of machine learning for safety management of li-ion battery energy storage[J]. Power system protection and control, 2022, 50(24): 178–187.
- [13] 高昊天, 陈云霞. 基于机器学习的锂离子电池健康状态分类与预测[J]. 北京航空航天大学学报, 2023, 49(12): 3467–3475.  
GAO Haotian, CHEN Yunxia. A machine learning based method for lithium-ion battery state of health classification and prediction[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(12): 3467–3475.
- [14] 毕贵红, 谢旭, 蔡子龙, 等. 动态条件下基于深度学习的锂电池容量估计[J]. 汽车工程, 2022, 44(6): 868–877,885.  
BI Guihong, XIE Xu, CAI Zilong, et al. Capacity estimation of lithium-ion battery based on deep learning under dynamic conditions[J]. Automotive engineering, 2022, 44(6): 868–877,885.
- [15] 毛玲, 温佳林, 赵晋斌, 等. 基于集成 ELM 的锂离子电池充电截止电压下的 SOC 和 SOH 联合估计[J]. 电力系统保护与控制, 2023, 51(11): 86–95.  
MAO Ling, WEN Jialin, ZHAO Jinbin, et al. Joint estimation of SOC and SOH at lithium-ion battery charging cut-off voltage based on an ensemble extreme learning machine[J]. Power system protection and control, 2023, 51(11): 86–95.
- [16] 王桥, 魏孟, 叶敏, 等. 基于 GWO-LSTM 与 LSSVM 的锂离子电池荷电状态与容量联合估计[J]. 汽车安全与节能学报, 2022, 13(3): 571–579.  
WANG Qiao, WEI Meng, YE Min, et al. Co-estimation of state of charge and capacity of lithium-ion battery based on GWO optimized LSTM and LSSVM[J]. Journal of automotive safety and energy, 2022, 13(3): 571–579.
- [17] 李超然, 肖飞, 樊亚翔, 等. 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(2): 681–692.  
LI Chaoran, XIAO Fei, FAN Yaxiang, et al. Joint estimation of the state of charge and the state of health based on deep learning for lithium-ion batteries[J]. Proceedings of the CSEE, 2021, 41(2): 681–692.
- [18] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in neural information processing systems, 2017, 30: 6000–6010.
- [19] 耿鑫月, 郑建飞, 胡昌华, 等. 多因素影响下双时间尺度退化设备剩余寿命预测[J/OL]. 哈尔滨工程大学学报, 2023: 1–8. (2023–09–05)[2024–08–03]. <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=HEBG20230904001&dbname=CJFD&dbcode=CJFQ>.  
GENG Xinyue, ZHENG Jianfei, HU Changhua, et al. Prediction of residual life of degraded equipment with double time scales under the influence of multiple factors[J/OL]. China industrial economics, 2023: 1–8. (2023–09–05)[2024–08–03]. <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=HEBG20230904001&dbname=CJFD&dbcode=CJFQ>.
- [20] GAO Mingyu, SHEN Handan, BAO Zhengyi, et al. A correlation-augmented informer-based method for state-of-health estimation of Li-ion batteries[J]. IEEE sensors journal, 2024, 24(3): 3342–3353.
- [21] 张博玮, 郑建飞, 胡昌华, 等. 基于流模型的缺失数据生成方法在剩余寿命预测中的应用[J]. 自动化学报, 2023, 49(1): 185–196.  
ZHANG Bowei, ZHENG Jianfei, HU Changhua, et al. Missing data generation method based on flow model and its application in remaining life prediction[J]. Acta automatica sinica, 2023, 49(1): 185–196.
- [22] 欧阳天成, 徐裴行, 叶今禄, 等. 数据采集异常下的车用动力电池状态监测与故障诊断[J]. 中国电机工程学报, 2023, 43(15): 6040–6050.  
OUYANG Tiancheng, XU Peixing, YE Jinlu, et al. States monitoring and fault diagnosis of vehicular power batteries under abnormal data acquisition[J]. Proceedings of the CESS, 2023, 43(15): 6040–6050.
- [23] 吴晗, 王士同. 不完整数据分类与缺失信息重要性识别特权 LSSVM[J]. 智能系统学报, 2023, 18(4): 743–753.  
WU Han, WANG Shitong. Privileged LSSVM for classification and simultaneous importance identification of missing information on incomplete data[J]. CAAI transactions on intelligent systems, 2023, 18(4): 743–753.
- [24] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和堆叠降噪自编码器-长短期记忆的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(01): 289–302.  
YIN Jie, LIU Bo, SUN Guobing, et al. Transfer learning

- dae-lstm for remaining useful life prediction of li-ion batteries[J]. Transactions of china electrotechnical society, 2024, 39(01): 289–302.
- [25] 张洪生, 尚鑫磊. 基于 DAE-BLS 的锂离子电池剩余使用寿命预测方法[J]. 计算机集成制造系统, 2025, 31(3): 1038–1047.  
ZHANG Hongsheng, SHANG Xinlei. Prediction method for remaining useful life of lithium-ion batteries based on DAE-BLS[J]. Computer integrated manufacturing systems, 2025, 31(3): 1038–1047.
- [26] 原江鑫, 何莉萍, 李耀东, 等. 电动汽车 BMS 从控板热分析及散热优化[J]. 汽车工程, 2024, 46(1): 128–138.  
YUAN Jiangxin, HE Liping, LI Yaodong, et al. Thermal analysis and optimization design of a BMS slave unit for electric vehicles[J]. Automotive engineering, 2024, 46(1): 128–138.
- [27] 李青, 郭仲杰, 陈浩, 等. 面向多节电池管理系统的高精度电压监测技术[J]. 传感技术学报, 2020, 33(7): 950–955.  
LI Qing, GUO Zhongjie, CHEN Hao, et al. High precision voltage monitoring technology for multi-cell battery management system[J]. Chinese journal of sensors and actuators, 2020, 33(7): 950–955.
- [28] 蒋玮, 王晓东, 杨永标, 等. 电动汽车电池组智能管理及其无线传感器网络路由协议[J]. 电力系统自动化, 2015, 39(18): 62–68.  
JIANG Wei, WANG Xiaodong, YANG Yongbiao, et al. Electric vehicle smart battery management and its wireless sensor network protocol[J]. Automation of electric power systems, 2015, 39(18): 62–68.
- [29] ZHOU Haoyi, ZHANG Shanghang, PENG Jieqi, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI, 2021: 11106–11115.
- [30] 杜先君, 贾亮亮. 基于优化堆叠降噪自编码器的滚动轴承故障诊断[J]. 吉林大学学报(工学版), 2022, 52(12): 2827–2838.  
DU Xianjun, JIA Liangliang. Fault diagnosis of rolling bearing based on optimized stacked denoising auto encoders[J]. Journal of Jilin University (engineering and technology edition), 2022, 52(12): 2827–2838.
- [31] CHEN Zhiqiang, XU Tingbing, DU Changde, et al. Dynamical channel pruning by conditional accuracy change for deep neural networks[J]. IEEE transactions on neural networks and learning systems, 2021, 32(2): 799–813.

### 作者简介:



彭自然, 副教授, 主要研究方向为人工智能、信号处理和智能检测仪表。主持湖南省自然科学基金项目、湖南省教育厅科学研究项目 10 余项, 获发明专利授权 2 项, 出版学术专著 2 部, 发表学术论文 20 余篇。E-mail: [peng-ziran@hut.edu.cn](mailto:peng-ziran@hut.edu.cn)。



王顺豪, 硕士研究生, 主要研究方向为电动汽车动力电池健康状态和荷电状态估算。E-mail: [3130669501@qq.com](mailto:3130669501@qq.com)。



肖伸平, 教授, 主要研究方向智能控制、时延系统鲁棒控制理论和时延系统稳定性分析。主持国家自然科学基金项目、国家火炬计划和国家重点研发计划项目子课题 10 余项, 获发明专利授权 5 项、实用新型专利授权 5 项。发表学术论文 80 余篇, ESI 1% 高被引论文 5 篇。E-mail: [xsp@hut.edu.cn](mailto:xsp@hut.edu.cn)。