

DOI:10.19651/j.cnki.emt.2415884

基于 TCT-PSA 模型的锂离子电池健康状态评估<sup>\*</sup>李红磊<sup>1</sup> 刘勋川<sup>2</sup> 高 强<sup>3</sup> 贺国刚<sup>2</sup> 韩 松<sup>1</sup>

(1. 贵州大学电气工程学院 贵阳 550025; 2. 贵州金元绿链物流开发有限公司 贵阳 550081;

3. 国网辽宁省电力有限公司丹东供电公司 丹东 118000)

**摘 要:** 针对传统估计方法估计精度低的问题,本文提出了一种基于时空卷积网络与金字塔分割注意力融合 Transformer(TCT-PSA)模型框架的新型健康状态(SOH)估计方法。首先对 NASA 电池数据集进行预处理,然后从锂离子电池充电阶段提取健康因子(HF),采用 Pearson 相关系数和灰色关联分析法量化 HF 与锂离子电池 SOH 的相关性,并将相关性高的 HF 输入到 TCT-PSA 模型中,SOH 为模型输出。为了验证模型的有效性,利用 TCT-PSA 模型估计各组电池容量衰减;使用不同模型估计各组电池的 SOH 并进行比较,并利用分位数估计,验证 TCT-PSA 模型的准确性和鲁棒性。实验结果表明,通过对各组电池测试集和训练集容量衰减的平均绝对估计误差的验证,所提模型的误差均在 2% 以内;所提模型估计各组电池 SOH 的平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)均在 0.035 以内;在锂离子电池 SOH 分位数估计中最高精度达到 99.82%。

**关键词:** 锂离子电池;TCT-PSA;SOH 估计;HF;Pearson 相关系数;灰色关联分析法

**中图分类号:** TN-9 **文献标识码:** A **国家标准学科分类代码:** 120.30

## Lithium-ion battery state of health estimation based on TCT-PSA modeling

Li Honglei<sup>1</sup> Liu Xunchuan<sup>2</sup> Gao Qiang<sup>3</sup> He Guogang<sup>2</sup> Han Song<sup>1</sup>

(1. School of Electrical Engineering, Guizhou University, Guiyang 550025, China;

2. Guizhou Jinyuan Green Chain Logistics Development Co., Ltd., Guiyang 550081, China;

3. State Grid Liaoning Electric Power Company Limited Dandong Power Supply Company, Dandong 118000, China)

**Abstract:** Aiming at the problem of low estimation accuracy of traditional estimation methods, this paper proposes a novel state of health (SOH) estimation method based on the framework of spatio-temporal convolutional network and Pyramid Squeeze Attention Fusion (TCT-PSA) model. Convolutional Transformer-Pyramid Squeeze Attention (TCT-PSA) modeling framework for a novel state of health (SOH) estimation method. The NASA battery dataset was first preprocessed, and then the health factor (HF) was extracted from the charging stage of lithium-ion batteries, and the correlation between HF and SOH of lithium-ion batteries was quantified by using Pearson's correlation coefficient and grey correlation analysis, and the HF with high correlation was inputted into the TCT-PSA model, and SOH was the model output. In order to verify the validity of the model, the TCT-PSA model was used to estimate the capacity degradation of each group of batteries; the SOH of each group of batteries was estimated using different models and compared, and the quantile estimation was used to verify the accuracy and robustness of the TCT-PSA model. The experimental results show that the errors of the proposed models are within 2% by validating the average absolute estimation errors of the capacity decays in the test and training sets of each group of batteries; the average absolute error (MAE), the average absolute percentage error (MAPE), and the root mean square error (RMSE) of the proposed models for estimating the SOH of each group of batteries are within 0.035; and the highest accuracy of the quartile estimation of the SOH of lithium-ion batteries is 99.82%. The highest accuracy reaches 99.82%.

**Keywords:** lithium-ion battery; TCT-PSA; SOH estimation; HF; Pearson correlation coefficient; gray correlation analysis method

## 0 引 言

锂离子电池的健康状态(state of health, SOH)评估对

于保证电池运行的可靠性和安全性至关重要<sup>[1]</sup>。随着充放电次数的增加,锂离子电池阳极、电解质和阴极中发生电化学副反应,其性能逐渐下降。SOH 估计一般用于评价电池

收稿日期:2024-04-19

<sup>\*</sup> 基金项目:贵州省优秀青年科技人才项目(黔科合平台人才[2021]5645)、贵州省科技支撑计划项目([2023]329)、贵州省科技支撑计划项目([2023]290)资助

的退化程度,准确可靠的 SOH 估计是电动汽车平稳运行和安全运行的保障<sup>[2]</sup>。

SOH 作为电池管理系统的一个极其重要的指标,但无法直接测量,需通过电压、电流、温度和阻抗等可测量参数来准确估计 SOH<sup>[3]</sup>。SOH 估计方法可分为 3 类:1)实验方法(如库仑计数法、开路电压法等)<sup>[4]</sup>;2)基于模型的方法(如扩展卡尔曼滤波、电路模型等)<sup>[5]</sup>;3)数据驱动方法(包括深度学习和机器学习方法)<sup>[6]</sup>。实验方法简洁明了,能够获得丰富的退化信息并准确估计电池的 SOH。然而,这种方法不仅耗时且昂贵,还会永久性地影响电池的使用寿命。在基于模型的方法中,以阻抗和容量等参数为指标,利用结果量化电池的退化程度。然而,由于实现难度大且计算量大,该算法在在线状态估计中的应用受到限制。数据驱动模型是一个“黑匣子”,利用常规监测和历史收集的系统运行数据(如温度、电流),来模拟电池外部参数之间的复杂关系。数据驱动的方法比基于模型的方法更快,涉及的复杂力学更少<sup>[7]</sup>。近几年深度学习被广泛地应用于电池的 SOH 估计之中。Ye 等<sup>[8]</sup>提出了一种称为物理信息神经网络(physics-informed neural network, PIFNN)的方法估计 SOH,对模糊神经网络的预测进行了物理约束的二次“训练”,进一步增强了可解释性,提高了估计精度。Zhang 等<sup>[9]</sup>提出了一种扩张的残差回归网络来估计锂离子电池在各种和不完全充电条件下的 SOH,并通过与机器学习算法和浅卷积网络的比较,验证了该方法的准确性和鲁棒性。Lin 等<sup>[10]</sup>提出了一种考虑电池内阻的数据驱动方法来估算锂离子电池的 SOH,将等效电路模型(equivalent circuit model, ECM)和数据驱动方法有效地结合在一起。采用蚁群算法对解释助推机(explanation boosting machine, EBM)模型参数进行优化,从而提高了模型的鲁棒性。陈媛等<sup>[11]</sup>提出了一种结合降噪自编码器(denoising auto encoder, DAE)和门控递归单元(gated recurrent unit, GRU)的递归神经网络混合模型,用于电池 SOH 估计,提高了算法精度及抗干扰能力。Gu 等<sup>[12]</sup>提出了一种新的基于数据预处理方法和卷积神经网络(convolutional neural network, CNN)-Transformer 框架的 SOH 估计方法,解决了如何更好地捕捉局部和全局信息。

尽管现有的估计方法可以准确地估计电池 SOH,但由于其在长序列建模方面的可扩展性有限且训练过程耗时,学习长期依赖关系是一大挑战。对于神经网络来说,学习长依赖关系的能力主要受到正向和反向信号路径长度的影响。随着序列中组件之间路径长度的增加,捕获长期依赖关系的效率会显著降低。

为了解决上述问题,本文提出了一种基于时空卷积网络和金字塔分割注意力融合 Transformer(temporal convolutional transformer-pyramid squeeze attention, TCT-PSA)的方法来评估锂离子电池的 SOH。与传统方法不同,TCT-PSA 模型能够考虑不同的输入变量,并通过

变量选择网络(variable selection network, VSN)智能地选择最显著的健康因子(health factor, HF)。该模型在每次充放电后对锂离子电池的 SOH 估计表现出良好的性能,能够准确拟合电池 SOH 衰减曲线。同时,采用 Pearson 相关系数和灰色关联分析法综合选取相关系数高的 HF,以优化锂离子电池 SOH 估计的输入。实验结果表明,TCT-PSA 模型不仅提高了估计精度,还具有较高的鲁棒性。

## 1 TCT-PSA 模型构建

### 1.1 GRN 与 VSN

外生输入和目标之间的确切关系通常是事先未知的,因此很难预见哪些变量是相关的<sup>[13]</sup>。此外,很难确定非线性处理的程度该多大,为了使模型能够灵活地处理非线性,使用门控残差网络(gated residual network, GRN),其接受一个主要输入  $\mathbf{a}$  和一个可选的上下文向量  $\mathbf{c}$ ,结果是:

$$\begin{cases} \text{GRN}_{\omega}(\mathbf{a}, \mathbf{c}) = \text{LayerNorm}(\mathbf{a} + \text{GLU}_{\omega}(\boldsymbol{\eta}_1)) \\ \boldsymbol{\eta}_1 = \mathbf{W}_{1,\omega}\boldsymbol{\eta}_2 + \mathbf{b}_{1,\omega} \\ \boldsymbol{\eta}_2 = \text{ELU}(\mathbf{W}_{2,\omega}\mathbf{a} + \mathbf{W}_{3,\omega}\mathbf{c} + \mathbf{b}_{2,\omega}) \end{cases} \quad (1)$$

式中:ELU 为指数线性单位激活函数,  $\boldsymbol{\eta}_1 \in R^{d_{\text{bmodel}}}$ 、 $\boldsymbol{\eta}_2 \in R^{d_{\text{bmodel}}}$  为中间层,LayerNorm 为标准层归一化,  $\omega$  为表示权重的指数。令  $\boldsymbol{\gamma} \in R^{d_{\text{bmodel}}}$  为输入,则 GLU 可表示为:

$$\text{GLU}_{\omega}(\boldsymbol{\gamma}) = \sigma(\mathbf{W}_{4,\omega}\boldsymbol{\gamma} + \mathbf{b}_{4,\omega}) \odot (\mathbf{W}_{5,\omega}\boldsymbol{\gamma} + \mathbf{b}_{5,\omega}) \quad (2)$$

式中:  $\sigma(\cdot)$  是 sigmoid 激活函数,  $\mathbf{W}_{(\cdot)} \in R^{d_{\text{bmodel}} \times d_{\text{bmodel}}}$  为权重,  $\mathbf{b}_{(\cdot)} \in R^{d_{\text{bmodel}}}$  为偏差,  $\odot$  为元素的 Hadamard 乘积。

VSN 是通过选择重要的特征,减少不必要的噪声输入,以提高建模性能。假设在时间点  $t$  下,有  $m_x$  个变量,对连续型变量,做线性转换。变换后的变量是  $d_{\text{bmodel}}$  维度向量,转换后的变量即为  $\xi_t^{(j)}$ ,  $j$  为第  $j$  个变量,  $t$  为时间点  $t$ 。对于历史输入,放平后的结果是:

$$\Xi_t = [\xi_t^{(1)T}, \dots, \xi_t^{(m_x)T}]^T \quad (3)$$

利用这些转换变量,进行变量选择:

$$\tilde{\xi}_t = \sum_{j=1}^{m_x} v_{jt}^{(j)} \tilde{\xi}_t^{(j)} \quad (4)$$

式中:其中,  $v_{jt}^{(j)}$  为特征选择的权重,  $\tilde{\xi}_t^{(j)}$  为非线性处理后的特征。GRN 模块和 VSN 结构如图 1 所示。

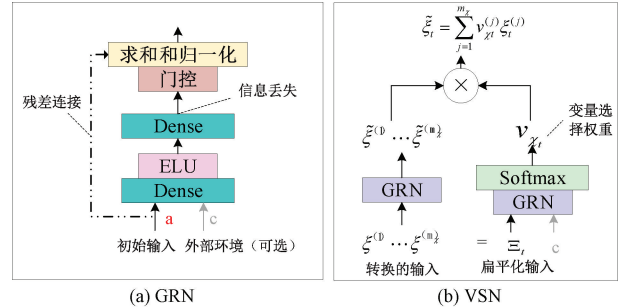


图 1 GRN 与 VSN 结构示意图

Fig. 1 Schematic diagram of GRN and VSN structure

在 GRN 与 VSN 中,为了提供适度的模型容量以捕捉复杂的时间序列模式,选取嵌入维度为 64 和隐藏层维度为 256;为提供稳定的训练过程,学习率设置为 0.000 5。为保证训练稳定性的同时提高了计算效率,批量大小设置为 32;训练轮数为 100 确保模型有足够的时间收敛。

### 1.2 PSA

金字塔分割注意力(pyramid squeeze attention,PSA)模块的主要作用是增强网络对多尺度信息的表示能力<sup>[14]</sup>,并实现局部和全局通道注意力之间的有效交互,从而提高网络的性能和泛化能力。

在进行 SOH 估计时,PSA 为在多个尺度上捕捉特征,适应不同的特征尺寸,将金字塔层级数设置为 3;为了能够在减少通道数量的同时,保持关键信息,降低计算复杂度,设置 0.5 的压缩因子;为了保证足够的注意力机制复杂度的同时,保持计算效率,选取 8 个多头注意力。

首先,通过分割金字塔链接(squeeze pyramid concat,SPC)分割通道,然后提取每个通道特征图上的空间信息进行多尺度特征。为降低参数量,应用多尺度卷积内核分组卷积提取不同尺度特征图的空间信息,多尺度内核大小与组大小的关系表示为:

$$G = \begin{cases} 2^{\frac{K-1}{2}}, & K > 3 \\ 1, & K = 3 \end{cases} \quad (5)$$

式中:数量  $K$  为核大小, $G$  为组大小。尺度特征图生成函数为:

$$F_i = \text{Conv}(K_i \times K_i, G_i)(X_i), i = 0, 1, 2, \dots, S-1 \quad (6)$$

最后得到多尺度融合之后的特征图:

$$F = \text{Cat}([F_0, F_1, \dots, F_{S-1}]) \quad (7)$$

第二,利用分割提取权重(squeeze-and-excitation weight,SEWEIGHT)模块提取不同尺度特征图的通道注意力,得到每个不同尺度上的通道注意力向量。如下:

$$Z_i = \text{SEWeight}(F_i), i = 0, 1, 2 \dots S-1 \quad (8)$$

式中: $Z_i \in \mathbf{R}^{C \times 1 \times 1}$  为注意力权重,整个多尺度通道注意力权重向量为:

$$Z = Z_0 \oplus Z_1 \oplus \dots \oplus Z_{S-1} \quad (9)$$

第三,利用 Softmax 重新标定多尺度通道注意力向量进行特征,得到新的注意力权重:

$$\text{att}_i = \text{Softmax}(Z_i) = \frac{\exp(Z_i)}{\sum_{i=0}^{S-1} \exp(Z_i)} \quad (10)$$

将式(10)进行拼接融合,得到整个通道注意力向量:

$$\text{att} = \text{att}_0 \oplus \text{att}_1 \oplus \dots \oplus \text{att}_{S-1} \quad (11)$$

第四,将重新校准后的权重与相应的特征图进行逐元素相乘,以生成多尺度特征信息的注意力加权特征图。

### 1.3 TCN

为了提取局部特征,使用时间卷积网络(temporal

convolutional network,TCN)<sup>[15]</sup>,为了捕捉较深的时间依赖性,设置层数为 4;为了能够在时间序列上进行平滑的局部模式捕捉,同时保持模型的计算效率,设置卷积核大小为 3;其他超参数设置同 1.1 所述。其结构如图 2 所示。

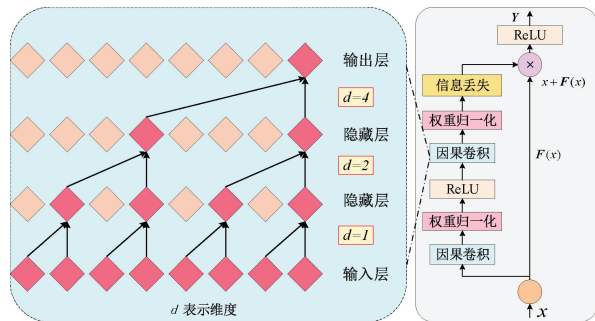


图 2 TCN 结构示意图

Fig. 2 Schematic diagram of TCN structure

TCN 的显著特征是:

1)在这个体系结构中,卷积操作具有因果性,未来的信息不会“泄露”到过去。

2)这个结构适用于任意长度的序列,将其映射到同样长度的输出序列。它强调了利用深度网络(通过增强残差层)和扩张卷积的组合来构建有效的长历史视窗,从而提升网络对远处过去的预测能力。TCN 不使用门控机制,具有更长的记忆。

为了实现特征 1),TCN 使用因果卷积;为了实现特征 2),TCN 使用了一维全卷积网络(fully convolutional network,FCN)架构,即  $\text{TCN} = 1\text{D} + \text{因果卷积}$ 。

对于一维序列,输入  $x \in \mathbf{R}^n$  和滤波器  $f: \{0, \dots, k-1\} \rightarrow \mathbf{R}$ ,定义序列元素  $s$  上的扩张卷积运算  $F$  为:

$$F(s) = (x *_{d,f})(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \quad (12)$$

式中: $d$  为扩张因子, $k$  为滤波器尺寸, $s-d \cdot i$  表示过去的方向。

### 1.4 所提的 TCT-PSA 模型

在介绍完上述各模块后,得到最终的 TCT-PSA 模型。整个 TCT-PSA 模型如图 3 所示,首先是输入层,由 3 个部分组成:静态信息、历史信息和未来信息。静态信息涵盖了不变的特征,如客户基本信息;历史信息是希望预测的变量的过去数据;未来信息则包括其他变量的预测或者已知的未来事件。其次是变量选择层,它的任务是从输入数据中选择重要的特征,并将其传递到后续的编码层。编码层采用了 TCN,它首先接收来自变量选择层的重要特征,并从这些特征中提取局部信息。然后,通过局部和全局通道注意力的有效交互,采用了 PSA 机制,以进一步提升特征表征的质量。这些编码后的特征被传送到多个解码层最终输出所需的分位数估计结果。

通过多层次的信息提取和交互,从输入数据中学习并预测目标变量的分布情况。这一体系结构使得模型能够

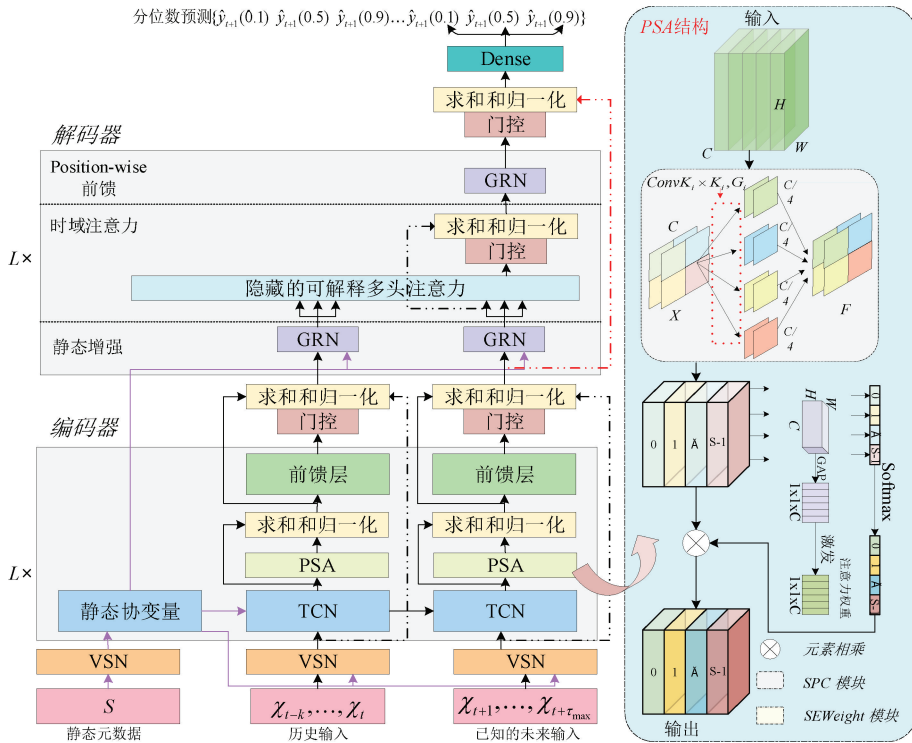


图 3 所提的 TCT-PSA 模型

Fig. 3 The proposed TCT-PSA model

更好地捕获数据中的复杂关系和模式,从而提高了估计的准确性和鲁棒性。

TCT-PSA 模型通过联合最小化分位数损失来训练,并对所有分位数输出求和:

$$(\Omega, W) = \sum_{y_t \in \Omega} \sum_{q \in \mathcal{Q}} \sum_{\tau=1} \frac{QL(y_t, \hat{y}(q, t - \tau, \tau), q)}{M\tau_{max}} \quad (13)$$

$$QL(y, \hat{y}, q) = q(y - \hat{y})_+ + (1 - q)(\hat{y} - y)_+ \quad (14)$$

式中:  $\Omega$  是包含  $M$  个样本的训练数据的域,  $W$  表示权重,  $q$  是输出分位数的集合, 即  $q = \{0.1, 0.5, 0.9\}$ 。

## 2 SOH 估计模型

### 2.1 SOH 估计流程

结合上文所提模型结构, 本文提出的基于 TCT-PSA 的锂离子电池 SOH 估计模型的完整流程如图 4 所示。

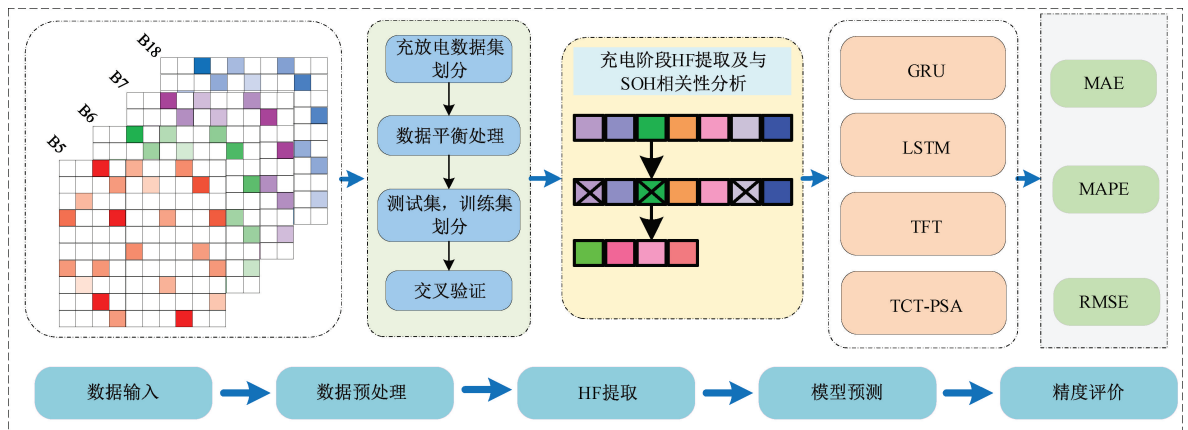


图 4 基于 TCT-PSA 的锂离子电池估计流程

Fig. 4 TCT-PSA based estimation flow for Li-ion battery

步骤 1) 输入 NASA 原始数据集, 包含四组电池数据集 B0005, B0006, B0007, B00018, 数据集中包含每一次循环的充电或放电数据。步骤 2) 数据预处理。利用

MATLAB 内置函数加载原始数据集, 得到每组电池的充放电数据集; 接着, 进行数据平衡处理, 确保数据集中不同类别的样本数量均匀, 清洗缺失值, 提取充电数据、计算电



池测量电压、电流、负载电压、负载电流、温度和时间的平均值;最后,利用 `cvpartition` 函数分别将每组电池的充放电数据划分为 80% 的训练集和 20% 的测试集。步骤 3) 在电池充电阶段提取 HF, 采用 Pearson 相关系数和灰色关联分析法量化 HF 与锂离子电池 SOH 的相关性, 然后, 对相关性高的 HF 采用最小-最大值特征尺度方法进行归一化, 从而加速训练过程, 达到最小代价函数。最后, 将相关性高的 HF 输入到 TCT-PSA 模型中。步骤 4) 进行 SOH 估计。为了验证模型的有效性, 利用 TCT-PSA 模型估计各锂离子电池容量衰减。接着, 使用不同模型与所提模型估计锂离子电池的 SOH 并进行比较, 验证 TCT-PSA 模型的准确性。步骤 5) 模型评价。通过 TCT-PSA 估计每个锂离子电池测试集和训练集的容量衰减, 使用平均绝对误差 (average absolute error, MAE) 验证该模型的有效性; 利用评价指标 MAE、平均绝对百分比误差 (average absolute percentage error, MAPE)、均方根误差 (root mean square error, RMSE) 验证所提模型与其他模型估计锂离子电池 SOH 的准确性。

2.2 特征提取

为实现锂离子电池 SOH 的在线监测, 选择适当的输

入特征来反映电池的老化情况。本文从充电阶段提取输入特征, 因为在放电阶段, 电池的变化较大, 难以提取稳定的特征<sup>[16]</sup>。电池老化与电压、电流、内阻和温度曲线的变化一致。但这些数据由非均匀采样获取, 且数据量庞大, 导致处理困难<sup>[17]</sup>。因此, 提取适当的 HF 以描述这些曲线的趋势对锂离子电池 SOH 至关重要。

本文从充电曲线中选取 7 个 HF 进行分析, 其中恒流充电下有时间  $t_1$ 、温度  $T_1$ 、电压积分  $L_1$ ; 恒压充电下有时间  $t_2$ 、温度  $T_2$ 、电流  $L_2$ ; 贯穿整个充电阶段的内阻  $R$ 。将以上 HF 进行分组, 即时间、温度、电压电流、内阻。

采用 Pearson 相关系数和灰色关联分析法对以上 7 个 HF 与 SOH 进行相关性分析, 公式分别如下:

$$\gamma = cov(X, Y) / \sqrt{S_X S_Y} \tag{15}$$

$$\lambda(X, Y) = \frac{\sum_{k=1}^n \lambda(X(k), Y(k))}{n} \tag{16}$$

式中:  $X, Y$  分别代表 HF 和 SOH,  $\gamma, \lambda$  的绝对值越大, 代表 HF 和 SOH 的关联性越强。锂离子电池的 HF 与 SOH 的 Pearson 相关系数和灰色关联系数分别如表 1 和 2 所示, 各 HF 的 Pearson 相关系数图如图 5 所示。

表 1 HF 的 Pearson 相关系数

Table 1 Pearson correlation coefficients for HF

| 型号    | 不同 HF 对应的 Pearson 相关系数 |        |       |        |       |        |       |
|-------|------------------------|--------|-------|--------|-------|--------|-------|
|       | $t_1$                  | $t_2$  | $T_1$ | $T_2$  | $L_1$ | $L_2$  | $R$   |
| B0005 | 0.911                  | -0.902 | 0.944 | -0.157 | 0.992 | -0.875 | 0.924 |
| B0006 | 0.924                  | -0.245 | 0.931 | -0.024 | 0.991 | -0.625 | 0.956 |
| B0007 | 0.919                  | 0.775  | 0.904 | 0.854  | 0.996 | 0.487  | 0.915 |
| B0018 | 0.902                  | 0.782  | 0.913 | 0.602  | 0.995 | 0.874  | 0.901 |

表 2 HF 的灰色相关系数

Table 2 Gray correlation coefficients of HF

| 型号    | 不同 HF 对应的灰色相关系数 |       |       |       |       |       |       |
|-------|-----------------|-------|-------|-------|-------|-------|-------|
|       | $t_1$           | $t_2$ | $T_1$ | $T_2$ | $L_1$ | $L_2$ | $R$   |
| B0005 | 0.903           | 0.805 | 0.921 | 0.526 | 0.932 | 0.875 | 0.924 |
| B0006 | 0.914           | 0.545 | 0.923 | 0.624 | 0.941 | 0.685 | 0.916 |
| B0007 | 0.931           | 0.755 | 0.917 | 0.658 | 0.912 | 0.687 | 0.905 |
| B0018 | 0.914           | 0.732 | 0.903 | 0.742 | 0.925 | 0.774 | 0.908 |

由表可知:  $t_1, T_1, L_1, R$  的 Pearson 相关系数和灰色关联系数都大于 0.9; 由图 5 可知, 上述 4 个 HF 之间具有有较高的相关性, 因此, 采用其 4 个作为所提模型的输入特征。

2.3 SOH 定义和模型评价指标

SOH 通常是通过循环过程中实际容量超过名义容量来计算的。因此, 当实际容量低于故障阈值 (例如, 其额定容量的 70%) 时, 认为达到了电池的寿命终止, 需及时更换




图 5 Pearson 相关系数图

Fig. 5 Pearson correlation coefficient plot

锂电池<sup>[18]</sup>。通常, 一个新鲜的锂电池被认为是 100% 健康的, 它的健康水平会随着循环周期而下降。考虑阶段信息, 定义索引  $H_{c,i}$  表示第  $c^{\text{th}}$  阶段的 SOH, 如下:

$$H_{c,i} = Q_{c,i} / Q \in [0, 1] \tag{17}$$

式中:  $Q_{c,i}$  为第  $i^{th}$  个周期在第  $c^{th}$  阶段的电流容量,  $Q$  为电池的额定容量。

采用 MAE、RMSE、MAPE 评价所提模型的性能:

$$E_{MAE} = \frac{1}{L} \sum_{i=1}^L |Y_i - Y'_i| \tag{18}$$

$$E_{MAPE} = \frac{1}{L} \sum_{i=1}^L \left| \frac{Y_i - Y'_i}{Y_i} \right| \times 100\% \tag{19}$$

$$E_{RMSE} = \sqrt{\frac{1}{L} \sum_{i=1}^L (Y_i - Y'_i)^2} \tag{20}$$

其中,  $Y_i$  和  $Y'_i$  分别表示第  $i$  个样本的真实值和预测值,  $L$  为样本个数。

3 算例分析

3.1 SOH 估计模型的有效性验证

锂离子电池的性能退化包括整个退化过程中的多个退化行为,被认为是一个多级特征。根据先验知识,将整个生命周期分为健康阶段、慢退化阶段和快速退化阶段 3 个阶段。

本文采用的数据来自美国航天局 (National Aeronautics and Space Administration, NASA) 锂离子电池老化数据集,从中选择了不同老化工况条件下的 B0005、6、7、18 号电池为实验对象,具体信息如表 3 所示。各组实验都是在常温下进行的,且充电截止电压均为 4.2 V,恒流充电电流均为 1.5 A,放电电流都是 2 A。通过保持实验条件的一致性,可以更好地控制其他可能影响电池 SOH 估计的变量,确保对比实验的可靠性和准确性。通过 python 3.8 和 matlab2022b 进行实验。

表 3 4 组电池的充放电循环数据

Table 3 Charge/discharge cycle data of four groups of batteries

| 型号    | 电池循环状态       |              |              |            | 温度/<br>℃ |
|-------|--------------|--------------|--------------|------------|----------|
|       | 充电截止<br>电压/V | 放电截止<br>电压/V | 充电恒定<br>电流/A | 放电<br>电流/A |          |
| B0005 | 4.2          | 2.7          | 1.5          | 2          | 24       |
| B0006 | 4.2          | 2.5          | 1.5          | 2          | 24       |
| B0007 | 4.2          | 2.2          | 1.5          | 2          | 24       |
| B0018 | 4.2          | 2.5          | 1.5          | 2          | 24       |

图 6 为各电池容量衰减的过程。

由图 6 可知,4 组电池的容量都随着循环次数的增多而逐渐减小,可见,在前 60 次循环中,容量衰减较快,但电池 SOH 还是在 90% 以上,因此此阶段可定义为健康阶段;在 60~100 次循环中,容量进一步衰减,电池 SOH 逐渐降低,因此此阶段定义为慢退化阶段;在经过 100 次循环以后,随着电池内阻增大,容量降低,电池 SOH 进一步降低,达到临界值,此阶段称为快速退化阶段。




图 6 B5、B6、B7 和 B18 电池容量衰减曲线

Fig. 6 B5、B6、B7 and B18 cell capacity decay curves

为了验证所提模型的有效性,将 4 组电池的前 60 次容量循环数据作为训练集,60~100 次循环数据作为测试集。图 7 是利用 TCT-PSA 模型估计 B0005 电池容量衰减曲线及估计误差。

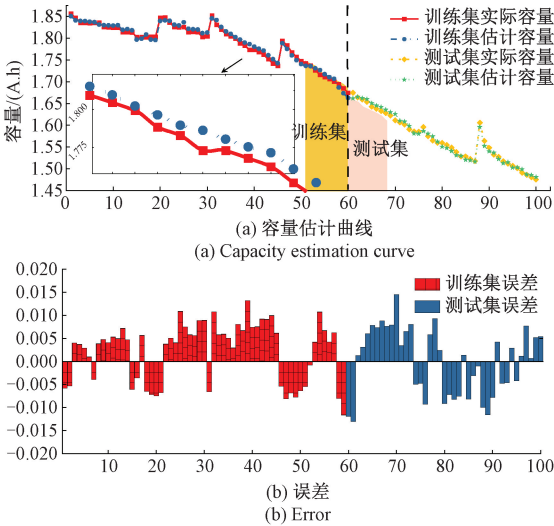


图 7 B5 电池容量衰减和误差图

Fig. 7 B5 Battery capacity decay and error plot

由图 7 可知,所提模型估计电池的容量衰减曲线去真实曲线非常接近,最大估计误差不超过 0.02。其他几组电池的估计误差如图 8 所示,各电池的平均绝对误差如表 4 所示。

由表 4 可知,利用 TCT-PSA 模型估计各电池的容量衰减的最大平均绝对误差不超过 0.02,说明该模型有较高的估计精度。因此,通过电池容量衰减验证了所提模型的有效性。此外,训练误差与测试误差水平大致相当,说明不存在普遍的过拟合问题。

由图 8 可知,各组电池的最大估计误差为 1.821%,最小误差为 0.984%,且各组电池的训练集测试集误差均大于训练集误差,说明了模型具有较优的泛化性。




图 8 B6、7、18 号电池平均绝对误差结果图

Fig. 8 Plot of average absolute error results for B6、7 and 18 cells

表 4 各电池的训练集和测试集平均误差

Table 4 Mean error of training and test sets for each cell

| 电池型号  | 平均绝对误差   |          |
|-------|----------|----------|
|       | 训练集      | 测试集      |
| B0005 | 0.012 38 | 0.013 45 |
| B0006 | 0.016 91 | 0.018 21 |
| B0007 | 0.013 54 | 0.015 23 |
| B0018 | 0.009 84 | 0.011 85 |

3.2 SOH 估计

根据以上模型有效性验证结果,得到 TCT-PSA 模型对容量估计有较高的估计精度。为了进一步验证该模型的准确性,利用所提模型估计各组电池 SOH,并与时域融合变换器(temporal fusion transformers,TFT)、长短期记忆网络(long short-term memory,LSTM)、GRU 模型比较估计结果,采用 RMSE、MAPE、MAE 三个指标评价模型性能。选取以上 4 组电池数据的前 120 次循环数据进行 SOH 评估,根据锂离子电池 SOH 定义,可以计算出各电池每次循环的真实 SOH,不同模型估计结果如图 9 和表 5 所示。

由图 9 和表 5 可知,TCT-PSA 模型对各电池的 SOH 估计曲线与真实 SOH 衰减曲线比较接近,所提的模型的各项评价指标都比其他模型低,其中 MAE 最大值为 0.031 9,最小值仅为 0.015 6,比 TFT 模型的 MAE 低 0.178;所提模型 MAPE 最大值为 0.026 3,最小值仅为 0.012 5;RMSE 最大值为 0.048 4,最小值仅为 0.009 7。TCT-PSA 模型的 MAE、MAPE 和 RMSE 误差均在 0.035 以内,说明了 TCT-PSA 模型估计锂离子电池 SOH 具有较高的估计精度。

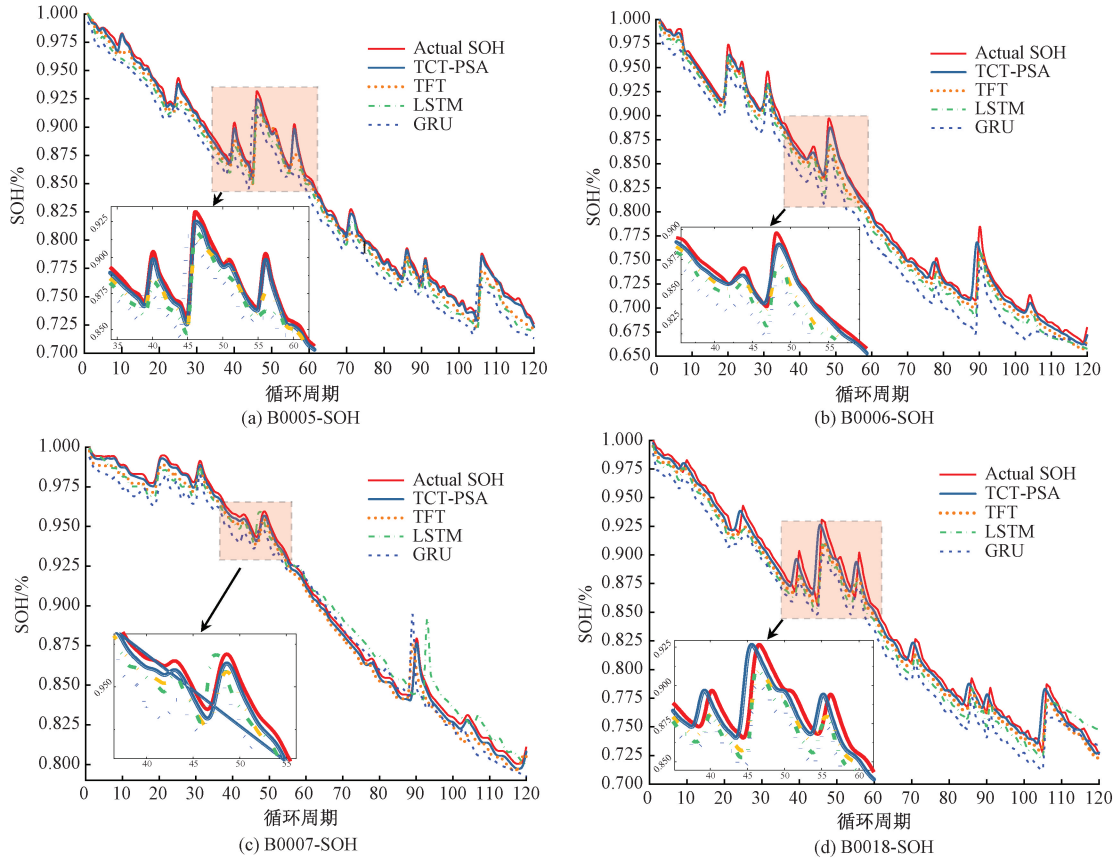


图 9 各电池在不同模型下的 SOH 估计结果示意图

Fig. 9 Schematic representation of SOH estimation results for each cell under different models

表 5 各电池的 SOH 在不同模型上的估计误差  
Table 5 Estimation error of SOH on different models  
for each cell

| 电池    | 模型      | MAE            | MAPE           | RMSE           |
|-------|---------|----------------|----------------|----------------|
| B0005 | GRU     | 0.035 6        | 0.052 5        | 0.065 4        |
|       | LSTM    | 0.032 2        | 0.042 8        | 0.048 7        |
|       | TFT     | 0.029 4        | 0.036 9        | 0.052 5        |
|       | TCT-PSA | <b>0.019 8</b> | <b>0.022 1</b> | <b>0.022 1</b> |
| B0006 | GRU     | 0.046 3        | 0.068 4        | 0.066 4        |
|       | LSTM    | 0.052 1        | 0.061 1        | 0.034 8        |
|       | TFT     | 0.033 4        | 0.032 4        | 0.042 5        |
|       | TCT-PSA | <b>0.015 6</b> | <b>0.008 4</b> | <b>0.011 3</b> |
| B0007 | GRU     | 0.053 0        | 0.052 9        | 0.075 3        |
|       | LSTM    | 0.042 3        | 0.037 5        | 0.066 2        |
|       | TFT     | 0.035 3        | 0.036 5        | 0.059 6        |
|       | TCT-PSA | <b>0.031 9</b> | <b>0.026 3</b> | <b>0.048 4</b> |
| B0018 | GRU     | 0.073 6        | 0.098 4        | 0.043 2        |
|       | LSTM    | 0.065 8        | 0.088 1        | 0.024 7        |
|       | TFT     | 0.067 7        | 0.065 1        | 0.026 3        |
|       | TCT-PSA | <b>0.022 3</b> | <b>0.012 5</b> | <b>0.009 7</b> |

3.3 电池 SOH 分位数估计

为了增加模型训练深度和鲁棒性,使用分位数估计。分位数估计可以降低对数据分布的假设,能够更准确地捕捉到数据的分布特征,因此能精确的体现模型的估计精度。以锂离子电池 B0005 为实验对象,利用所提模型与当前有代表性的先进 SOH 模型,如改进的量子粒子群算法与长短期记忆网络(improved quan-tum particle swarm optimization-LSTM, IQPSO-LSTM)<sup>[19]</sup>、递归高斯模型(Recurrent Gaussian process regression,R-GPR)<sup>[20]</sup>、特征融合的卷积神经网络(feature fusion-based convolutional neural network,FCNN)<sup>[21]</sup>、广义回归神经网络与量子遗传算法(generalized regression neural network-quantum genetic algorithm,GRNN-QGA)<sup>[22]</sup>分别估计锂离子电池的 SOH。图 10 为 B0005 的 SOH 在分位数估计下的精度示意图。

由图 10 可知,同一模型中,分位数为 0.9 的估计精度比分位数为 0.5 和 0.1 的高,其中,最高的模型估计精度达到了 0.978;不同模型中,TCT-PSA 模型的各分位数估计精度都比其他模型的高,其中,分位数为 0.5 的估计精度为 0.959,分位数为 0.1 的估计精度为 0.951。其他模型的分位数估计精度都达到了 0.930 以上。

根据以上结果,各模型选取 0.9 的分位数估计各组锂离子电池的 SOH,估计精度如图 11 所示。

由图 11 可知,TCT-PSA 模型对各组电池 SOH 的估计精度比其他模型高,最高达到 99.82%,最低精度也在 99.5%以上。除此之外,其他模型估计精度都在 0.835 以

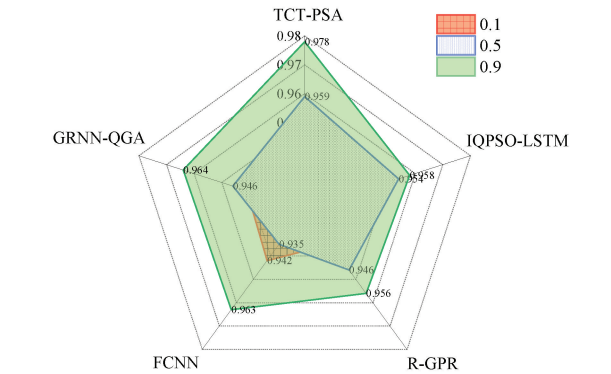


图 10 不同模型在 B0005 电池的分位数估计图  
Fig. 10 Quartile estimation plot for different models for B0005 cell

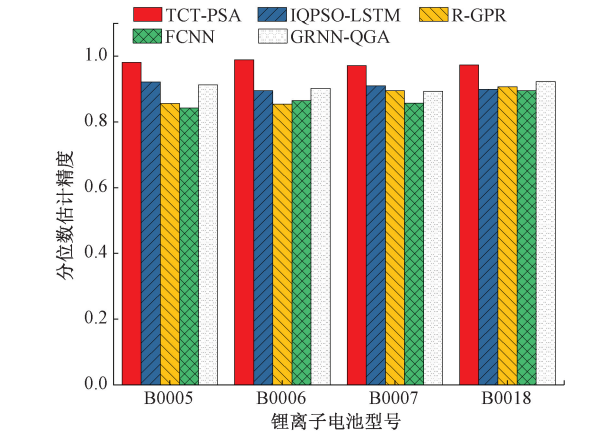


图 11 各模型的 0.9 分位数估计精度示意图  
Fig. 11 Schematic representation of the 0.9 quartile estimation accuracy of the models

上,其中 GRNN-QGA 模型较其他模型具有较高的估计精度。这些结果表明,使用分位数估计可以提高模型的准确性和鲁棒性,而 TCT-PSA 模型在估计锂离子电池 SOH 时表现出了明显的优势,具有更高的精度和更好的稳定性。

4 结 论

本文提出了一种新的方法:TCT-PSA 模型,实现锂离子电池 SOH 的准确估计,得出以下结论:

为了验证所提模型的有效性,本文利用 TCT-PSA 模型估计锂离子电池容量衰减。结果表明,TCT-PSA 模型估计各锂离子电池的容量衰减与真实的容量衰减曲线非常接近,训练集和测试集的平均误差不超过 0.02,验证了所提模型的有效性。

为了准确估计各组电池的 SOH,本文利用 GRU、LSTM、TFT 和 TCT-PSA 模型估计锂离子电池 SOH。在训练效果上,TCT-PSA 模型可以产生更低的损耗值。在测试过程中,TCT-PSA 模型比其他 3 种模型具有更强的竞争性能,其绝对估计误差、MAE、MAPE 和 RMSE 更低。

为了进一步验证所提模型准确性和鲁棒性,选取 0.9



的分位数估计各组电池的 SOH, 结果表明, TCT-PSA 模型估计各组电池 SOH 的精度比其他模型高, 最高达到 99.82%, 最低精度也在 99.5% 以上, 说明使用分位数估计可以提高模型的准确性和鲁棒性。

## 参考文献

- [1] LI Q, LI D, ZHAO K, et al. State of health estimation of lithium-ion battery based on improved ant lion optimization and support vector regression[J]. *Journal of Energy Storage*, 2022, 50: 104-118.
- [2] ZHU Y, JIANG B, ZHU J, et al. Adaptive state of health estimation for lithium-ion batteries using impedance-based timescale information and ensemble learning[J]. *Energy*, 2023, 284: 129-143.
- [3] 顾菊平, 蒋凌, 张新松, 等. 基于特征提取的锂离子电池健康状态评估及影响因素分析[J]. *电工技术学报*, 2023, 38(19): 5330-5342.
- GU J P, JIANG L, ZHANG X S, et al. Evaluation of lithium-ion battery health state and analysis of influencing factors based on feature extraction[J]. *Journal of Electrotechnology*, 2023, 38 ( 19 ): 5330-5342.
- [4] KHALEGHI S, HOSEN M S, VAN MIERLO J, et al. Towards machine-learning driven prognostics and health management of Li-ion batteries: A comprehensive review[J]. *Renewable and Sustainable Energy Reviews*, 2024, 192: 114-127.
- [5] WANG G, CUI N, LI C, et al. A state-of-health estimation method based on incremental capacity analysis for Li-ion battery considering charging/discharging rate[J]. *Journal of Energy Storage*, 2023, 73: 109-134.
- [6] LI F, MIN Y, ZHANG Y, et al. State-of-health estimation method for fast-charging lithium-ion batteries based on stacking ensemble sparse Gaussian process regression [J]. *Reliability Engineering & System Safety*, 2024, 242: 1097-1112.
- [7] YAO J, HAN T. Data-driven lithium-ion batteries capacity estimation based on deep transfer learning using partial segment of charging/discharging data[J]. *Energy*, 2023, 271: 1270-1283.
- [8] YE J, XIE Q, LIN M, et al. A method for estimating the state of health of lithium-ion batteries based on physics-informed neural network[J]. *Energy*, 2024, 294: 3082-3100.
- [9] ZHANG Y, WANG Y, XIA Y, et al. A deep learning approach to estimate the state of health of lithium-ion batteries under varied and incomplete working conditions[J]. *Journal of Energy Storage*, 2023, 58: 456-472.
- [10] LIN M, YAN C, WANG W, et al. A data-driven approach for estimating state-of-health of lithium-ion batteries considering internal resistance[J]. *Energy*, 2023, 277: 851-864.
- [11] 陈媛, 段文献, 何怡刚, 等. 带降噪自编码器的锂离子电池健康状态估计算法[J/OL]. *电工技术学报*, 1-17 [2024-09-04]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231644>.
- CHEN Y, DUAN W X, HE Y G, et al. Health state estimation algorithm for lithium-ion batteries with noise-reducing self-encoder [J/OL]. *Journal of Electrotechnology*, 1-17 [2024-09-04]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231644>.
- [12] GU X, SEE K W, LI P, et al. A novel state-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model [J]. *Energy*, 2023, 262: 268-284.
- [13] LIM B, ARIK S Ö, LOEFF N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting [J]. *International Journal of Forecasting*, 2021, 37(4): 1748-1764.
- [14] ZHANG H, ZU K, LU J, et al. EPSANet: An efficient pyramid squeeze attention block on convolutional neural network[C]. *Proceedings of the Asian Conference on Computer Vision*, 2022: 1161-1177.
- [15] BOCKRATH S, LORENTZ V, PRUCKNER M. State of health estimation of lithium-ion batteries with a temporal convolutional neural network using partial load profiles[J]. *Applied Energy*, 2023, 329: 689-702.
- [16] 戴俊彦, 夏明超, 陈奇芳. 基于双重注意力机制的电池 SOH 估计和 RUL 预测编解码模型[J]. *电力系统自动化*, 2023, 47(6): 168-177.
- DAI J Y, XIA M CH, CHEN Q F. Battery SOH estimation and RUL prediction coding and decoding model based on dual attention mechanism[J]. *Power System Automation*, 2023, 47(6): 168-177.
- [17] FEI W, LU D, LI Z. Research on the layout of urban disaster-prevention and risk-avoidance green space under the improvement of supply and demand match: The case study of the main urban area of Nanjing, China[J]. *Ecological Indicators*, 2023, 154: 657-672.
- [18] 朱振宇, 高德欣. 基于 CNN-BiLSTM 网络的锂离子电池健康状态检测方法[J]. *电子测量技术*, 2023, 46(3): 128-133.
- ZHU ZH Y, GAO D X. Health state detection method for lithium-ion battery based on CNN-BiLSTM

network[J]. Electronic Measurement Technology, 2023,46(3):128-133.

[19] PENG S, SUN Y, LIU D, et al. State of health estimation of lithium-ion batteries based on multi-health features extraction and improved long short-term memory neural network[J]. Energy, 2023, 282: 956-969.

[20] ZHOU Y, DONG G, TAN Q, et al. State of health estimation for lithium-ion batteries using geometric impedance spectrum features and recurrent Gaussian process regression[J]. Energy, 2023, 262: 657-671.

[21] LU Z, FEI Z, WANG B, et al. A feature fusion-based convolutional neural network for battery state-of-health estimation with mining of partial voltage curve [J]. Energy, 2024, 288: 969-981.

[22] XUE A, YANG W, YUAN X, et al. Estimating state of health of lithium-ion batteries based on generalized regression neural network and quantum genetic

algorithm[J]. Applied Soft Computing, 2022, 130: 688-703.

**作者简介**

**李红磊**, 硕士研究生, 主要研究方向为动力电池状态估计。  
E-mail:429316083@qq.com

**刘勋川**(通信作者), 中级工程师, 主要研究方向为热能与动力工程。  
E-mail:1158884148@qq.com

**高强**, 高级工程师, 主要研究方向为电力系统及自动化和网络安全。  
E-mail:ddgaoqiang@.163.com

**贺国刚**, 中级工程师, 主要研究方向为网荷储互动控制研究。  
E-mail:15242819@qq.com

**韩松**, 博士, 教授, 主要研究方向为交直流电力系统分析、新型电力电子装备以及配网规划。  
E-mail:shan@gzu.edu.cn