



## 基于热电联合模型和深度学习的锂离子电池温度估计方法

张有兵<sup>1</sup>, 鲍俊挺<sup>1</sup>, 潘红武<sup>2</sup>, 毛苑<sup>1</sup>, 张伟杰<sup>1</sup>, 张志明<sup>3</sup>

(<sup>1</sup>浙江工业大学信息工程学院, 浙江 杭州 310014; <sup>2</sup>国网湖州供电公司发展部, 浙江 湖州 313000; <sup>3</sup>瑞浦兰钧能源股份有限公司, 浙江 温州 325058)

**摘要:** 锂离子电池温度的准确估计作为电池管理系统(battery management system, BMS)的核心技术之一, 对电动汽车的安全运行具有重要意义。为此, 本研究提出一种结合模型与数据驱动的混合温度预测方法。首先, 构建由一阶RC等效电路模型与一阶热模型组成的热电联合模型, 并通过自适应遗忘因子递推最小二乘法(adaptive forgetting factor recursive least squares, VFFRLS)进行参数辨识; 而后, 为克服热等效电路模型在电池空间和材料上的简化导致对变化率较高温度区间的表征受限的问题, 设计一种自适应权重物理信息神经网络(adaptive weighted physics-informed neural network, AWPINN), 将联合模型辨识结果作为可学习参数的物理约束, 融合了数据驱动能力与模型物理机制。最后, 通过VFFRLS与AWPINN模型联合估计得到最终结果, 并与其他数据驱动模型的对比, 证明所提出的温度预测方法的优越性。实验结果表明, 在20℃环境下, 本方法的平均绝对误差为0.242, 均方根误差为0.4069, 决定系数达0.9693, 性能优于常见模型。在0~40℃范围内, 本模型亦保持良好的预测能力, 验证了在不同温度条件下的适应性与实用性。

**关键词:** 锂离子电池; 温度预测; 递推最小二乘法; 参数辨识; 物理信息神经网络

doi: 10.19799/j.cnki.2095-4239.2025.1109

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2026) 04-1363-12

## Lithium-ion battery temperature estimation method based on thermoelectric combined model and deep learning

ZHANG Youbing<sup>1</sup>, BAO Junting<sup>1</sup>, PAN Hongwu<sup>2</sup>, MAO Yuan<sup>1</sup>, ZHANG Weijie<sup>1</sup>,  
ZHANG Zhiming<sup>3</sup>

(<sup>1</sup>College of Information Engineering, Zhejiang University of Technology, Hangzhou 310014, Zhejiang, China;

<sup>2</sup>State Grid Huzhou Power Supply Company Development Department, Huzhou 313000, Zhejiang, China;

<sup>3</sup>REPT BATTERO Energy Co., Ltd, Wenzhou 325058, Zhejiang, China)

**Abstract:** Accurate temperature prediction methods for lithium-ion batteries are crucial for timely detection and mitigation of thermal runaway, ensuring battery safety. This study proposes a hybrid temperature-prediction framework that integrates physics-based (model-driven) and neural network (NN; data-driven) methodologies. First, the framework establishes a thermoelectric coupled model integrating a first-order resistor-capacitor electrical model with a first-order thermal model, followed by parameter identification via adaptive forgetting factor

收稿日期: 2025-12-11; 修改稿日期: 2026-01-01。

基金项目: 国家自然科学基金(U22B20116); 浙江省科技厅尖兵领雁计划项目(2024C01059)。

第一作者: 张有兵(1971—), 男, 博士, 教授, 研究方向为智能电网、分布式发电及新能源优化控制、电动汽车入网、电力系统通信、电能质量监控, E-mail: youbingzhang@zjut.edu.cn; 通信作者: 张志明, 高级工程师, 研究方向为新能源汽车动力电池开发及测试, E-mail: zhzhm2@163.com。

引用本文: 张有兵, 鲍俊挺, 潘红武, 等. 基于热电联合模型和深度学习的锂离子电池温度估计方法[J]. 储能科学与技术, 2026, 15(4): 1363-1374.

**Citation:** ZHANG Youbing, BAO Junting, PAN Hongwu, et al. Lithium-ion battery temperature estimation method based on thermoelectric combined model and deep learning[J]. Energy Storage Science and Technology, 2026, 15(4): 1363-1374.

recursive least squares (VFFRLS). To address the diminished precision of the equivalent thermal model in regions of rapid temperature changes due to spatial and material simplifications, an adaptiveweighted physics-informed NN (AWPINN) is introduced. This framework integrates data-driven flexibility with model physics by incorporating the output of the thermoelectric coupled model as a learnable parameter constraint. Experimental validation at 20°C demonstrates that the proposed AWPINN method achieves a mean absolute error of 0.242, a root-mean-square error of 0.4069, and a coefficient of determination of 0.9693, outperforming conventional benchmarks. Further, it maintains excellent predictive capability across a broad operational range of 0—40°C, validating the adaptability and practicality of the model under varying temperature conditions.

**Keywords:** lithium-ion battery; temperature prediction; recursive least squares method; parameter identification; physics-informed neural network

锂离子电池以高功率密度、高能量密度、长使用寿命和耐用的循环性能而成为新一代电动汽车的首选动力源<sup>[1]</sup>。然而,锂离子电池容易受到各种工作条件的影响,这些条件可能导致电滥用<sup>[2]</sup>、热滥用<sup>[3]</sup>和机械滥用<sup>[4]</sup>。任何形式的滥用都可能导致锂离子电池热失控,致使温度升高,从而带来燃烧甚至爆炸的风险。尤其是在高放电率下,过高的电池温度会诱发电池爆炸。因此,及时且精准地监测锂离子电池温度对于其安全运行至关重要<sup>[5]</sup>。此外,电池温度还会影响锂离子电池的健康状态<sup>[6]</sup>(state of health, SOH)、荷电状态<sup>[7]</sup>(state of charge, SOC)和剩余容量<sup>[8]</sup>。因此,需要一种准确且经济高效的温度监测方法,以实现电池的安全运行及寿命延长。现有的温度预测方法可分为基于模型的温度预测和基于数据驱动的温度预测。

现有的基于模型的方法可以简单分为基于电化学模型和基于等效电路模型2种。其中,基于电化学模型的电池温度预测虽然有着极高的精度,但是其建模过于复杂且对参数的需求量过大,导致难以在实际中投入使用<sup>[9]</sup>。而基于等效电路模型的方法通过将电池的热容和热阻映射为电阻和电容等电气元件,并将温度信号转换为电位信号,以实现电池的实时温度模拟。Liu等<sup>[10]</sup>结合了二阶等效电路热模型和二阶RC等效电路模型,提出了一考虑电池内部耦合电化学反应、电池内部温度和SOC的电热联合模型,并采用粒子群优化算法(particle swarm optimization, PSO)和双时间窗法结合对模型进行离线辨识,采用双重自适应无迹卡尔曼滤波(dual unscented Kalman filter, DUKF)进行校正,

实现了SOC和电池温度的准确估计。Zhang等<sup>[11]</sup>将一阶RC等效电路模型作为电模型,而热模型部分采用二阶热模型,以捕获电池热行为之间的相互作用,从而实现电池行为的全面描述。基于模型的方法建模简单且算力负担小,但其因对电池热行为表征缺失而产生难以消除的误差。

与基于模型的方法相比,基于数据驱动的方法规避了对电池内部热行为机理的物理建模,利用采集的工况数据进行训练,从而实现高精度的温度预测<sup>[12]</sup>。Hussein等<sup>[13]</sup>基于人工神经网络(artificial neural network, ANN)构建了双层ANN模型以减少数据采集过程产生的误差,通过库仑计数法得到SOC预测电池的电压,再将预测结果与电流、SOC作为数据集预测电池温度变化;Jiang等<sup>[14]</sup>则应用精英遗传算法(elite genetic algorithm, EGA)获得关于温度的时间序列数据最优分割策略,结合双向长短期记忆网络(Bi-directional long short-term memory, BiLSTM),提出一种用于预测储能电站内电池组最高和最低温度的预测方法。虽然上述基于数据驱动的温度预测方法相较于基于模型的方法更容易实现且精度更高,但数据驱动方法需要大量的数据进行训练。而在数据采集过程中,为不破坏电池结构所采用的非侵入式测量方法造成的采集误差、采集过程中产生的累积误差,均会影响温度估计的准确性。同时,基于数据驱动的方法仅通过采集工况数据来预测电池的温度变化,从而丧失了对温度变化机理的解释。

然而,现有的研究大多关注电池处于稳态或恒流工况时的温度变化。电池在充放电过程中,其工况和环境因素往往是复杂多变的,电池可能会表现

出复杂的热动态特性，这种动态特性难以捕捉到<sup>[15-16]</sup>。因此，为了解决模型难以捕捉热动态特性的问题，也为了解决数据驱动方法在物理解释性上的缺失，本研究提出了一种基于自适应遗忘因子递推最小二乘法(adaptive forgetting factor recursive least squares, VFFRLS)与自适应权重物理信息神经网络(adaptive weighted physics-informed neural network, AWPINN)的锂离子电池热电联合建模与温度预测方法。首先，构建由一阶RC电模型与一阶热模型耦合的热电联合模型，并采用VFFRLS在线辨识模型参数；进一步，提出自适应权重物理信息神经网络AWPINN，将联合模型辨识结果作为可学习参数的上下限，通过多损失自适应权重参数策略融合数据驱动方法与物理机理，实现对电池温度的高精度预测。在动态工况下的实验结果表明，本方法在不同环境温度下均能准确跟踪电池温度变化，且其效果显著优于传统数据驱动模型，验证了模型在复杂与极端条件下的鲁棒性与适用性。

## 1 热电联合模型建模与参数辨识

本研究以锂离子电池常用等效电路模型为研究对象，常见的体现电特性的等效电路模型有内阻模型<sup>[17]</sup>、一阶和二阶RC模型<sup>[18]</sup>、戴维宁模型等<sup>[19]</sup>。本研究的电特性模型仅承担向热等效模型部分提供不易测量的参数值作用。而常见的热模型有电化学模型<sup>[20]</sup>、热失控模型<sup>[21]</sup>、等效电路模型等<sup>[22-23]</sup>。其中，热等效电路模型建模简单，算力负担小，在实际应用中易于实现，故选用一阶等效热模型来表征电池热行为。

### 1.1 一阶RC等效电路模型

要准确地获取电池电特性，首先需要选取合适的等效电路模型。通常模型的RC环节越多，模型的精度越高，但参数辨识的难度也会相应增加。综合考虑，本研究选取一阶RC等效电路模型作为电特性部分模型，既便于电池内部参数辨识，又考虑了电池极化效应的影响。

一阶RC等效电路模型如图1所示。其中， $R_o$ 为电池的欧姆内阻，表示电池电压的瞬间突变情况； $R_p$ 和 $C_p$ 分别为极化内阻和极化电容，其并联以表征电池电压的回弹特性； $U_p$ 为电阻 $R_p$ 和电容 $C_p$ 两端的电压； $U_{ocv}$ 为电池的开路电压； $U_{batt}$ 是电池的工作端电压； $I_{batt}$ 是电池的工作电流。

根据图1得到系统的状态表达式：




图1 一阶RC等效电路模型

Fig. 1 First-order RC equivalent circuit model

$$I_{batt} = C_p \frac{dU_p}{dt} + \frac{U_p}{R_p} \quad (1)$$

$$U_{ocv} = U_{batt} + I_{batt} R_o + U_p \quad (2)$$

为了对模型进行参数辨识，根据电路的状态表达式[式(2)]进行拉普拉斯变换，可以得到系统的传递函数：

$$G(s) = \frac{U'(s)}{I'(s)} = R_o + \frac{R_p}{sR_p C_p + 1} \quad (3)$$

式中， $U'$ 表示电池端电压 $U_{batt}$ 与电池开路电压 $U_{ocv}$ 之间的差。对模型的传递函数进行离散化处理，为了保证辨识结果的可靠性，采用如下的双线性变换法<sup>[24]</sup>对传递函数进行变换：

$$s = \frac{2}{T_s} \frac{1 - z^{-1}}{1 + z^{-1}} \quad (4)$$

式中， $T_s$ 表示电池数据的采样时间，将式(4)代入式(3)进行简化后可以得到：

$$U'(k) = a_1 U'(k-1) + a_2 I_{batt}(k) + a_3 I_{batt}(k-1) \quad (5)$$

式中， $a_1$ 、 $a_2$ 、 $a_3$ 分别为待辨识参数。首先根据最小二乘法的基本结构，令 $y(k) = U'(k)$ ， $\varphi(k) = [U'(k-1) I_{batt}(k) I_{batt}(k-1)]$ ， $\theta$ 为待辨识参数矩阵，其构成如下：

$$\begin{cases} \theta = [a_1 a_2 a_3] \\ a_1 = \frac{-T_s + 2R_p C_p}{T_s + 2R_p C_p} \\ a_2 = \frac{R_o T_s + R_p T_s + 2R_o R_p C_p}{T_s + 2R_p C_p} \\ a_3 = \frac{R_o T_s + R_p T_s - 2R_o R_p C_p}{T_s + 2R_p C_p} \end{cases} \quad (6)$$

### 1.2 一阶等效热模型

由锂离子电池内部结构及其工作原理可知，电池在工作期间伴随着大量内部热量的释放，从而电池内部温度将不断升高。Bernardi等<sup>[25]</sup>从电池内阻生热和熵增反应的角度提出了经典的电池生热速率模型：

$$\dot{Q} = \frac{1}{V} \left( U_{ocv} - U_{batt} - T \frac{dU_{ocv}}{dT} \right) \quad (7)$$

式中， $\dot{Q}$ 表示电池的生热速率； $V$ 为电池的体

积； $dU_{ocv}/dT$ 为熵变因子； $T$ 为电池温度。由欧姆定律对式(7)进行化简：

$$U_{ocv} - U_{batt} = I_{batt}(R_p + R_o) = I_{batt}R_e \quad (8)$$

式中， $R_e$ 是电池的内阻，其值为电池极化电阻 $R_p$ 与电池欧姆内阻 $R_o$ 之和，由一阶RC等效电路模型辨识结果提供。在正常工作情况下电池的副反应热一般是不会发生的，因此分析过程中，只考虑电池的内阻热和化学反应热：

$$Q = I_{batt}^2(R_p + R_o) - I_{batt}T \frac{dU_{ocv}}{dT} = I_{batt}^2R_e - IT \frac{dU_{ocv}}{dT} \quad (9)$$

基于生热模型，建立等效电路模型以实现电池温度的模拟。为了平衡模型精度与计算负担，假设电池内部材料均匀分布，并将电池单体视为一个整体热源，建立如图2所示的一阶等效热模型来反映电池的热动力学。

如图2，热阻 $R_T$ 表示电池温度 $T$ 与当前环境温度 $T_{amb}$ 之间的对流冷却； $C_T$ 为电池的集中热容。根据基尔霍夫电流定律和欧姆定律，建立如下关系式：




图2 一阶等效热模型

Fig. 2 First-order equivalent thermal model




图3 热电联合等效模型

Fig. 3 Thermo-electric combined equivalent model

根据电池充放电实验中采集的电压、电流数据，对电特性模型部分进行辨识和模拟，能够获得电池的内阻值 $R_o$ 的变化，并将内阻值代入式(9)，获得热模型部分的生热量 $Q$ 。在获取到生热量 $Q$ 作为热模型部分输入后，即可对热模型进行相应的辨识与模拟，获得电池的温度变化以对电特性模型进行温度补偿。此外，为了保证上述热电联合等效模型的收敛性与准确性，电池的电流输入需保证一定

$$C_T \frac{dT}{dt} = Q + \frac{T_{amb} - T}{R_T} \quad (10)$$

由此，得到了该热模型中的待辨识参数 $R_T$ 、 $C_T$ ，可以将式(10)改写为如下形式：

$$T(k+1) - T(k) = \frac{Q}{C_T} + \frac{T_{amb} - T}{R_T C_T} \quad (11)$$

根据最小二乘法的基本结构，令 $y(k) = T(k+1) - T(k)$ ， $\varphi(k) = [Q(k) T_{amb}(k) - T(k)]$ ，并定义待辨识参数矩阵 $\theta$ 为：

$$\theta = \left[ \frac{1}{C_T} \quad \frac{1}{R_T C_T} \right] \quad (12)$$

### 1.3 热电等效联合模型

对上述2种所选的模型进行分析后发现，一阶RC等效模型能够很好地表征电池的电特性以及老化效应特性，同时等效热模型也能够获取电池在运行过程中的热特性变化。但在实际应用中，电池热模型部分的生热量难以计算，导致单一热等效电路模型在实际应用中存在一定的局限性。而在单一电特性模型中，未考虑温度对电池充放电过程中的电特性影响，也会限制模型在实际应用中的适用性。因此，将电池的电等效电路模型和热等效电路模型联合在一起，二者相互作用，电池电等效电路模型部分的内阻值、开路电压等输出作为电池热等效电路模型的关键输入，热等效电路模型的温度输出不断校正电特性等效电路模型在不同温度下的参数变化。建立的热电联合等效电路模型如图3所示。

的动态变化特性，以确保在线辨识能准确辨识电特性部分参数，避免恒流或静置工况下的参数漂移导致的生热量计算误差。

## 2 模型参数辨识方法

### 2.1 FFRLS辨识法

递推最小二乘法<sup>[26]</sup>(recursive least squares, RLS)是参数辨识领域中广泛采用的一种方法，其

根据观测次序对新的观测数据进行参数修正, 随着时间的推移而获取高精度的结果。然而, 相对于其它辨识方法而言, RLS方法本身仍存在一些缺陷, 比如容易受到异常值的干扰, 对高斯噪声的滤除能力较为不足, 等等。为了克服这一问题, 在RLS方法中引入遗忘因子, 以主动遗忘部分旧数据, 提升最近数据的权重。因此, 带遗忘因子的递推最小二乘法 (forgetting factor recursive least squares, FFRLS) 的公式如下:

$$\begin{cases} \boldsymbol{\theta}(k) = \boldsymbol{\theta}(k-1) + \mathbf{K}(k)[y(k) - \boldsymbol{\varphi}^T(k)\boldsymbol{\theta}(k-1)] \\ \mathbf{K}(k) = \mathbf{P}(k-1)\boldsymbol{\varphi}(k)[\boldsymbol{\varphi}^T(k)\mathbf{P}(k-1)\boldsymbol{\varphi}(k) + \lambda]^{-1} \\ \mathbf{P}(k) = \frac{1}{\lambda} [\mathbf{I} - \mathbf{K}(k)\boldsymbol{\varphi}^T(k)]\mathbf{P}(k-1) \end{cases} \quad (13)$$

式中,  $\mathbf{K}(k)$ 代表 $k$ 时刻参数向量的增益;  $\mathbf{P}(k)$ 代表 $k$ 时刻状态估计值的误差协方差矩阵;  $\mathbf{I}$ 为单位矩阵;  $\lambda$ 为FFRLS中的遗忘因子, 通常为一个略小于1的常数; 而参数向量 $\boldsymbol{\theta}$ 即为与模型参数相关的目标参数值, 其通过迭代后可以得到模型中的各个参数。

## 2.2 改进的VFFRLS参数辨识法

在传统的FFRLS中, 定常数遗忘因子在处理简单数据时能够体现出较好的效果, 然而一旦出现较为复杂的辨识工况, 定常数遗忘因子的设定就会使得辨识精度下降。因此, 基于FFRLS方法, 将定常数遗忘因子进行自适应调整。自适应调整根据数据的变化和协方差矩阵的更新, 实时对辨识方法进行迭代和校正。针对这种自适应遗忘因子的概念, 其具体表达式如式(14)。

$$\lambda = 1 - \frac{e^2(k)}{1 + \mathbf{K}^T(k)\mathbf{P}(k)\mathbf{K}(k)} \quad (14)$$

根据式(14), 当系统状态发生显著变化时, 遗忘因子会迅速减小, 从而导致预测误差 $\mathbf{P}(k)$ 迅速增大。这个机制使得旧样本被迅速遗忘, 从而实现了系统最新状态的快速跟踪。随着新数据样本的输入, 新的学习模型逐渐趋于稳定, 预测误差 $\mathbf{P}(k)$ 逐渐减小, 相应地, 遗忘因子逐渐增大。这样, 随着输入数据的长度不断增加, 系统在稳态下具有更高的精度。综上所述, 本研究提出的VFFRLS的辨识公式如下:

$$\begin{cases} \boldsymbol{\theta}(k) = \boldsymbol{\theta}(k-1) + \mathbf{K}(k)[y(k) - \boldsymbol{\varphi}^T(k)\boldsymbol{\theta}(k-1)] \\ \mathbf{K}(k) = \mathbf{P}(k-1)\boldsymbol{\varphi}(k)[\boldsymbol{\varphi}^T(k)\mathbf{P}(k-1)\boldsymbol{\varphi}(k) + \lambda]^{-1} \\ \mathbf{P}(k) = \frac{1}{\lambda} [\mathbf{I} - \mathbf{K}(k)\boldsymbol{\varphi}^T(k)]\mathbf{P}(k-1) \\ \lambda = 1 - \frac{e^2(k)}{1 + \mathbf{K}^T(k)\mathbf{P}(k)\mathbf{K}(k)} \end{cases} \quad (15)$$

## 3 基于AWPINN的温度估计

根据上述所构建的热电联合等效模型, 通过所提出的VFFRLS进行参数辨识可获取模型的热特性变化。然而, 基于模型参数辨识结果进行仿真所获取的电池温度受到模型本身的设计缺陷影响, 在温度的表征上具有一定的限制。因此, 本研究将上述所构建的热电联合模型嵌入物理信息神经网络 (physics-informed neural network, PINN) 框架进行温度预测。PINN作为一种结合深度学习和物理学知识的机器学习模型, 其在学习过程中利用不同模型的物理特性对模型不断进行反馈修正, 从而提高模型的泛化能力。此外, 针对PINN模型框架中的多损失函数, 设计了一种AWPINN模型以实现自适应的电池温度预测。

### 3.1 AWPINN模型

#### 3.1.1 AWPINN模型结构

本研究所提出的AWPINN模型网络结构部分由常见的全连接神经网络 (fully connected neural network, FCNN) 构成。FCNN作为一种常规神经网络方法, 其网络结构仅包括输入输出层以及自定义数量的隐藏层, 如图4所示。若FCNN的输入集为 $\mathbf{x}$ , 则其映射为:

$$h^{l+1} = \sigma(W^l h^l + b^l), \quad l = 0, 1, \dots, L-1 \quad (16)$$

其中,  $h^l$ 表示分支输出特征,  $\sigma$ 为本研究所用激活函数。对于简单的标量预测任务, 常规的FCNN架构已足够胜任。




图4 FCNN结构示意图

Fig. 4 Schematic diagram of FCNN structure

此外, 对于AWPINN模型中各个FCNN位置的激活函数而言, 常规的tanh和sigmoid在学习过程中, 一旦遇到极端值, 极易导致输出过于平滑。因此, 本研究采用了sin作为激活函数, 相较于其他的激活函数, sin的周期性使其更适应周期性的

物理过程,且其保证了无限阶可导、梯度连续,而其独特的结构也保证了其具备克服渐进平坦化输出的能力。

$$\sigma_{\sin}(z) = \sin z \quad (17)$$

由式(17)可以看出,激活函数 $\sin$ 的梯度为 $\cos z$ ,其保证了激活函数无限阶可导且不易陷入平坦区。

### 3.1.2 损失函数

在PINN中,其物理信息主要嵌入在损失函数部分进行更新。本研究主要考虑了数据损失、物理信息损失以及初始值损失三类损失,在保证整体预测值与真实值之间的误差最小化的同时,保证所提出模型的微分方程和初始误差最小化。

本研究针对所提出的PINN模型的数据损失部分,选用了均方误差作为数据损失函数的计量方式,其损失函数如下:

$$\text{Loss}_{\text{data}} = \frac{1}{N} \sum_{i=1}^N |T_{\text{pre}}^i - T^i|^2 \quad (18)$$

式中, $N$ 表示不同温度数据的真实长度; $T_{\text{pre}}^i$ 表示预测温度; $T^i$ 表示电池真实温度。

与数据损失函数相似,对于联合模型的物理信息损失函数参考联合模型的热模型关系[式(10)],并将其转换为微分方程形式。则根据联合模型中热模型部分所设计的PINN中物理信息损失函数为

$$\text{Loss}_{\text{PDE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{dT}{dt} + \lambda_1 Q + \lambda_2 (T - T_{\text{amb}}) \right|^2 \quad (19)$$

式中, $\lambda_1$ 与 $\lambda_2$ 是由式(10)转换所得的可学习系数,这些系数是联合模型中热容和热阻的组合形式,在PINN训练过程中会不断根据损失进行拟合,直至物理信息损失最小。在基于PINN对联合模型进行温度预测的过程中,数据损失占据主导地位,其根据电池工况数据的温度预测差异进行调整。但是,电池在不同环境与工况下,其变化趋势必然不同。因此,物理信息损失根据模型的热传导原理,对不同条件的温度变化差异进行区分,进一步保证了温度预测的可行性。

此外,除了上述的数据损失和物理信息损失之外,电池的温度还受到其初始温度的影响。电池的初始温度决定了电池温度变化的起点,在某种程度上也限制或加强了电池在不同工况下温度变化的趋势。因此,本研究在上述两种损失的基础上,引入了初始温度损失。在电池温度变化的0时刻,此时电池电流变化为0,也就是电池生热量为0,该时

刻电池温度与环境温度相等。因此,热模型的初始温度损失为

$$\text{Loss}_{\text{initial}} = |T_0 - T_{\text{amb},0}|^2 \quad (20)$$

式中, $T_0$ 与 $T_{\text{amb},0}$ 分别表示电池本身以及环境温度值的初始值。

因此,在本研究的PINN模型中,总损失函数结合了数据损失、物理信息损失和初始温度损失,合并的损失函数如下:

$$\text{Loss}_{\text{total}} = \text{Loss}_{\text{data}} + \omega_{\text{PDE}} \text{Loss}_{\text{PDE}} + \omega_{\text{initial}} \text{Loss}_{\text{initial}} \quad (21)$$

式中, $\omega_{\text{PDE}}$ 和 $\omega_{\text{initial}}$ 分别表示物理信息损失和初始温度损失的权重,通常被设定为常数。

### 3.1.3 自适应损失平衡策略

然而在实际训练过程中,式(21)的不同损失项在量级和收敛速度上往往存在显著差异,采用固定的权重系数难以实现最优的训练效果,且权重参数的调试过程繁琐。为了解决这一问题,本研究采用梯度归一化的思想实现损失权重的动态自适应,以促进模型的稳定和高效收敛。

该自适应策略的核心机制如下:在每次训练迭代中,我们首先计算各项损失相对于网络的输出 $\hat{y}$ ,即预测温度 $T_{\text{pre}}$ 的梯度 $\nabla \hat{y}_{\text{data}}$ 、 $\nabla \hat{y}_{\text{PDE}}$ 和 $\nabla \hat{y}_{\text{initial}}$ 。这些梯度反映了各项损失对模型预测变化的敏感程度。为了平衡不同损失项对模型参数更新的贡献,定义物理信息瞬时权重 $\hat{\omega}_{\text{PDE}}$ 如下:

$$\hat{\omega}_{\text{PDE}} = \frac{\max(|\nabla \hat{y}_{\text{data}}|)}{\text{mean}(|\nabla \hat{y}_{\text{PDE}}|) + \varepsilon} \quad (22)$$

其中, $\varepsilon$ 为一个极小的常数,其目的是保证瞬时权重的数值稳定性。当数据损失的梯度远大于物理损失时, $\hat{\omega}_{\text{PDE}}$ 增大,从而提升物理损失在总损失中的比重,引导模型更好地遵循物理规律。而 $\hat{\omega}_{\text{initial}}$ 的计算方式也与 $\hat{\omega}_{\text{PDE}}$ 一样,其计算式如下:

$$\hat{\omega}_{\text{initial}} = \frac{\max(|\nabla \hat{y}_{\text{data}}|)}{\text{mean}(|\nabla \hat{y}_{\text{initial}}|) + \varepsilon} \quad (23)$$

同时,为了防止权重在训练过程中发生剧烈振荡,引入了指数移动平均(exponential moving average, EMA)对权重进行平滑更新。因此,得到实际权重 $\omega_{\text{PDE}}$ 和 $\omega_{\text{initial}}$ 如下:

$$\begin{cases} \omega_{\text{PDE}}(t) = (1 - \gamma) \omega_{\text{PDE}}(t-1) + \gamma \hat{\omega}_{\text{PDE}} \\ \omega_{\text{initial}}(t) = (1 - \gamma) \omega_{\text{initial}}(t-1) + \gamma \hat{\omega}_{\text{initial}} \end{cases} \quad (24)$$

其中, $\gamma$ 为[0,1]的平滑因子,控制权重更新速

率。此外，设置权重的上下界 $[\omega_{\min}, \omega_{\max}]$ ，将 $\omega_{\text{PDE}}$ 和 $\omega_{\text{initial}}$ 约束在合理范围内，以确保训练的数值稳定性。

通过这种自适应平衡策略，模型能够在训练初

期和后期自动调整对数据和物理知识的依赖程度，有效避免了手动调参的负担，并显著提升了模型的收敛速度和最终精度。本研究所提出的AWPINN模型结构如图5所示，其超参数设置如表1所示。

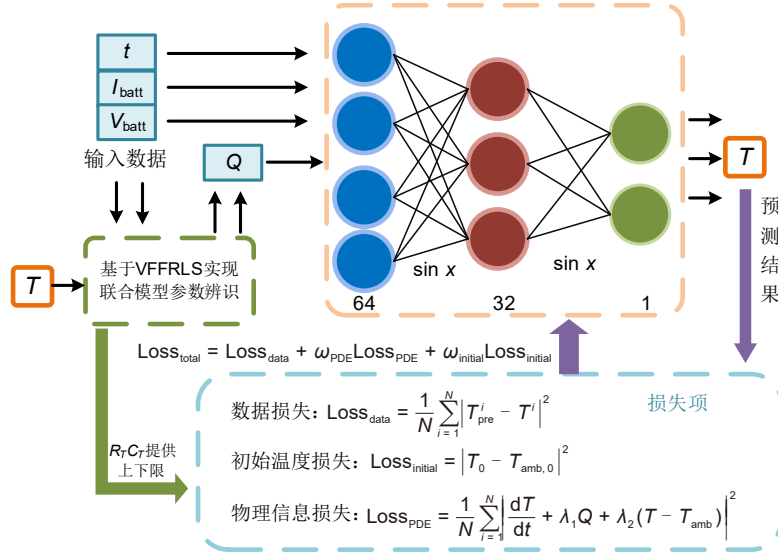


图5 AWPINN结构示意图  
Fig. 5 Schematic diagram of AWPINN structure

表 1 AWPINN 模型超参数设置  
Table 1 AWPINN model hyperparameter

超参数	设置值
隐藏层数量	3
神经元数量	[64, 32, 1]
激活函数	sin x
优化器	Adam
学习率	$10^{-3}$
迭代次数	5000

### 3.2 基于 AWPINN 的温度预测框架

为了基于所提出的AWPINN模型实现热电联合等效模型的温度预测，AWPINN模型计算多类损失的数据需求，设定模型的输入为电池充放电时间、生热量、电压以及电流，而输出为电池温度 $T$ 。

此外，为了防止AWPINN模型在训练过程中因追求损失最小化，而导致式(17)中方程系数出现违背物理规律，根据热电联合等效模型辨识结果有效值设置可学习系数 $\lambda_1$ 、 $\lambda_2$ 的上下限，以保证可学习参数结果的物理可解释性。

因此，本研究所提出的基于AWPINN方法预测温度的步骤如下。

(1) 为了实现对所提出的温度预测框架的训练

与预测，在不同环境温度下对电池进行混合脉冲功率特性测试(hybrid pulse power characterization, HPPC)。

(2) 针对采集到的实验数据对热电联合等效模型进行VFFRLS辨识，获取初步的辨识结果。

(3) 根据采集的数据区分训练集与测试集，并且初始化AWPINN。

(4) 根据辨识结果设置可学习参数上下限，并通过选定的优化器和嵌入的物理信息损失进行AWPINN的训练。

(5) 针对训练后的模型进行测试集的预测与验证。

## 4 实验验证与分析

本研究所用的电池为PokefiSY300-1型锂聚合物电池，其标称电压为3.8 V，容量为3850 mAh。实验在恒温箱条件下进行，采用数据记录仪Hioki-LR8450采集数据。本研究在室温分别为0℃、10℃、20℃、30℃、40℃的情况下采集电池在HPPC工况下的正负极温度，取均值作为电池的整体温度，将所有采集数据用于模型的训练与预测。

#### 4.1 VFFRLS辨识联合模型结果

为验证所提出联合模型的辨识算法部分,采用20℃室温的HPPC数据对电特性部分进行参数辨识,其辨识结果如图6所示。由图6(a)可以看到,对于最小二乘法无法避免地出现辨识初期数据的剧烈振荡,VFFRLS能够很快地趋于稳定,其中收敛后 $R_0$ 的值基本上稳定在80 mΩ左右。为了验证辨识过程的准确性,将辨识结果在Simulink中建立模型进行验证,电压验证结果如图6(b)所示。在VFFRLS的辨识方法下辨识结果数据模拟后得到的电压值与实际端电压值之间的最大误差为0.12 V。造成这种0.1 V左右的电压误差的原因是在每一个

放电区间,VFFRLS检测到系统状态发生突变,自适应遗忘因子 $\lambda$ 根据式(14)迅速减小。这一动态调整机制虽然在瞬间导致了协方差矩阵膨胀,从而产生短暂的预测误差,但其核心优势在于能够快速“遗忘”旧的历史数据,使算法迅速捕捉到当下最新的电特性参数特性。随后,随着电流进入稳态, $\lambda$ 自动回升至接近1,有效抑制了数据噪声。由图6(b)可见,误差在脉冲后迅速收敛至0,证明方法成功解决了传统固定遗忘因子难以实现快速跟踪与稳态抗噪之间均衡的问题,从而实现了整体辨识结果均方根误差(root mean square error, RMSE)仅为1.84%的高精度表现。




图6 电特性模型参数辨识验证结果: (a) 辨识结果; (b) 电压对比

Fig. 6 Electrical characteristic model parameter identification verification results: (a) Identification results; (b) voltage comparison

在获取高精度的电特性部分模型参数后,通过辨识获取内阻值 $R_0$ ,根据式(9)得到热模型部分的输入生热量 $Q$ 。同样采用VFFRLS对热模型进行参数辨识,其参数辨识结果如图7(a)所示。

同样地,将辨识结果在Simulink中建立相应模型进行验证,结果如图7(b)所示。结果表明,在VFFRLS的辨识方法下辨识结果的温度波形与真实温度波形相似。但是可以发现,在每一个升温区间,仿真温度难以跟随真实温度上升到区间最大值。这是因为等效热模型作为一种集总参数模型,其将电池的关键部分视为一个单一、均匀的热源。

这导致其难以完整地描述电池温度变化这种非线性的时变物理过程。因此,为了消除这种因模型本身构造的缺陷而产生的温度误差,将热模型的部分参数辨识结果作为后续AWPINN模型可学习参数的上下限参考,以实现更为精确的电池温度预测。在本研究中,设定AWPINN模型的可学习参数的上下限范围为通过辨识结果极值的1.5倍。而1.5倍的松弛约束边界能够平衡AWPINN模型的物理约束与数据拟合能力。一方面,松弛区间的设定赋予神经网络一定的自由度,以修正热模型描述电池复杂热特性时的固有偏差;另一方面,基于辨识结果的约束有效防止了神




图 7 热模型部分辨识结果：(a) 辨识结果；(b) 温度对比

Fig. 7 Thermal model part identification results: (a) Identification results; (b) temperature comparison

神经网络在训练过程中陷入物理不可解释的局部极小值，从而保证了模型的物理一致性。

#### 4.2 AWPINN 模型温度预测结果分析

以 HPPC 数据集作为模型输入，以 8 : 2 的比例划分为训练集和测试集。训练集用于 AWPINN 模型学习能力的训练，测试集用于评估 AWPINN 模型对温度的预测能力。根据验证结果选用平均绝对误差(mean absolute error, MAE)、RMSE 以及决定系数(coefficient of determination,  $R^2$ )对温度预测结果进行评估，表达式如下：

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (25)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (26)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (27)$$

式中， $y_i$  和  $\hat{y}_i$  分别表示真实值和估计值， $\bar{y}$  表示平均值。

##### 4.2.1 模型有效性对比分析

首先，为了验证本研究所提出模型的优越性，对比本研究所提出的 AWPINN 模型与其他基础数据驱动模型 FCNN、LSTM、PINN 在 20℃ 室温条件下针对 HPPC 工况的温度预测能力。预测结果如图 8 所示，其评价指标计算结果如表 2 所示。




图 8 不同数据驱动模型预测结果及其误差对比

Fig. 8 Prediction results and error comparison of different data-driven models

表 2 不同数据驱动模型预测结果评价指标对比

Table 2 Comparison of evaluation indexes of prediction results of different data-driven models

所用模型	MAE	RMSE	$R^2$
AWPINN	0.242	0.4069	0.9693
PINN	0.6053	1.013	0.809
LSTM	1.3910	1.1794	0.7419
FCNN	1.0986	1.3652	0.6543

从图8中可以看到, 4组数据驱动模型对于电池温度的变化均表现出了一定的拟合能力, 4组数据驱动模型均能够预测到电池温度变化的整体趋势, 其中AWPINN模型对于温度预测的效果明显优于其余3组神经网络, 其RMSE仅为0.4069。此外, 根据误差曲线可以观察到, AWPINN模型在电池快速升温过程中局部高温点的预测能力远远优于其余3组模型。这种优越的局部捕捉能力主要得益于可学习参数上下限的约束策略, 该策略将解空间限制在合理的物理范围内, 使得模型在数据剧烈波动时仍能遵循热力学规律进行梯度下降, 避免了纯数据驱动模型因过拟合噪声而产生的非物理振荡。结合表2可以看出, 在相同的模型结构基础上, AWPINN模型的MAE、RMSE和 $R^2$ 均优于其余3组模型。相较于普通的PINN模型, AWPINN模型的MAE降低了60.02%, RMSE降低了59.83%,  $R^2$ 提高了19.81%。此外, AWPINN根据辨识结果引入可学习参数上下限, 使得模型的物理可解释性远远强于其余3种模型。

#### 4.2.2 不同测试温度下模型有效性分析

但在不同的环境温度下, 在电池充放电过程中其内部的电化学反应表现会出现不同程度的变化, 从而其温度变化率和温度变化范围可能会发生变化。因此, 本研究在4.1.2节对环境温度为20℃时模型验证结果的基础上, 验证了环境温度在0℃、10℃、30℃、40℃的情况下AWPINN模型的预测能力。其测试集的预测结果以及误差如图9所示, 而不同室温下的预测结果评价指标表现如表3所示。

根据图9可以看到, 首先在0~40℃, AWPINN模型在HPPC工况下均能够完整地预测到电池温度的变化趋势, 且对于较难预测的每一个脉冲阶段的局部峰值温度也基本能够预测到其温度的局部峰值。但是, 图9(a)~(d)的波形预测结果在处于脉冲工况下电池温度快速上升区间出现了较大的突变误差, 该误差的绝对值范围在1~2℃, 也是造成表3中评价指标偏高的最大影响因素。造成这种预测误差的主要原因是在脉冲放电阶段, 产热速率迅速发生剧烈变化, 电池温度场呈现出高度的瞬态和非均匀特性, 导致AWPINN模型在变化率极高的温度区间时, 其解空间由于物理规律和实际数据之间的分裂造成波动。此外, 在图9中可以很明显地看到电池温度在变化过程中是伴随着一个小范围波动,

这样的波动主要是由于实际采集过程中传感器的精度影响, 而在秒级的电池温度波动并不符合物理逻辑, 因此由这种传感器误差造成的预测误差是可以接受的。而结合表3的评价指标可以看到, 本研究提出的AWPINN模型在0~40℃的环境温度条件下均保持了较高的精度表现。相较之下, 模型在10℃及以下的表现略逊于20℃以上的表现, 但是其最大MAE和RMSE分别为0.392和0.573, 最小 $R^2$ 仍保持在0.94以上, 说明本模型在低温条件下依然保持优秀的预测能力。

## 5 结论

本研究首先根据电池的电与热特性之间的耦合关系建立了由一阶RC等效电路模型和一阶等效热模型组成的锂离子电池热电联合等效模型, 通过VFFRLS在线辨识了模型参数。实验结果表明, VFFRLS方法对电特性模型辨识得到的电压验证RMSE仅为1.84%, 验证了该辨识方法的优越性。但因热等效电路模型本身缺陷, 在对电池热模型部分进行辨识时, 仅能拟合温度的大致变化曲线。

为了解决热特性模型在温度拟合上的固定缺陷, 进一步提出了AWPINN模型, 该模型结合了深度学习与物理约束, 通过梯度归一化实现动态自适应损失平衡策略。将热电联合等效模型辨识结果作为AWPINN中可学习参数的上下限, 有效解决了传统物理模型精度受限与纯神经网络缺乏可解释性的矛盾, 可确保温度预测在全工况下既精准又符合物理逻辑。在不同室温条件下的HPPC实验验证表明, 该混合模型具有较高的预测精度, 其最大MAE和RMSE分别为0.392和0.573, 最小 $R^2$ 仍保持在0.94以上。在常温条件下, 与传统的FCNN、LSTM和PINN模型相比, AWPINN模型具备更强的预测能力。相较于PINN, AWPINN模型MAE降低了60.02%, RMSE降低了59.83%,  $R^2$ 提高了19.81%。

在未来的工作中, 首先将考虑探寻更为合理的输入特征, 以消除模型预测中的局部大误差项, 从而扩展模型在更为复杂且无规律的工况下仍能保证高精度的预测效果。此外, 将进一步通过实验获取电池不同部位的温度数据并进行针对热模型部分的模型拓展。同时, 在电池的电模型等效电路中, 不同温度及温度变化趋势对参数的影响机制需要深入

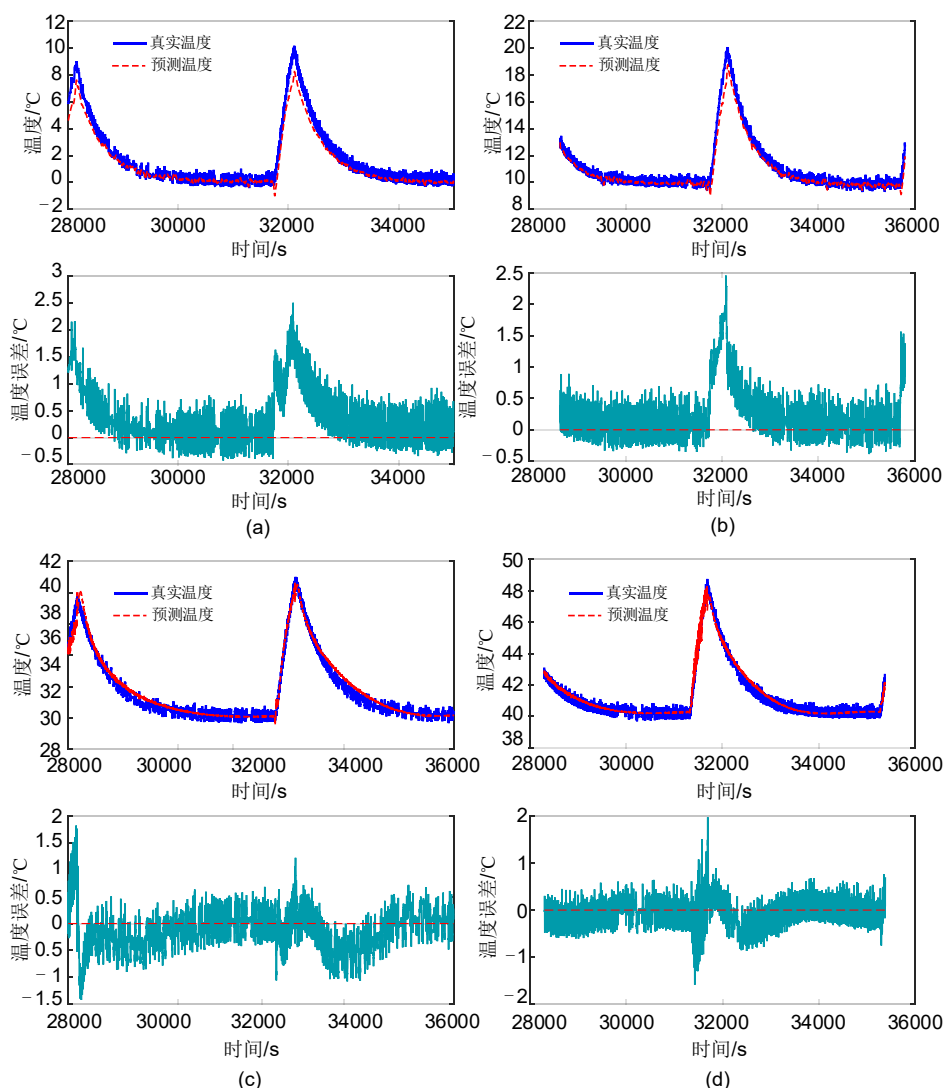


图 9 不同环境温度下预测结果及其误差对比：(a) 0°C；(b) 10°C；(c) 30°C；(d) 40°C

Fig. 9 Prediction results and error comparison under different ambient temperatures: (a) 0°C; (b) 10°C; (c) 30°C; (d) 40°C

表 3 不同环境温度下模型预测结果评价指标对比

Table 3 Comparison of evaluation indexes of model prediction results under different ambient temperatures

环境温度	MAE	RMSE	$R^2$
0°C	0.392	0.573	0.943
10°C	0.279	0.4358	0.9549
30°C	0.2775	0.371	0.9715
40°C	0.1958	0.2644	0.9772

研究，构建更为精细的热电联合等效模型，进一步提高电池建模的精度和泛化能力。

参考文献

[1] XIE J, LU Y C. A retrospective on lithium-ion batteries[J]. Nature

Communications, 2020, 11: 2499. DOI: 10.1038/s41467-020-16259-9.

[2] LARSSON F, MELLANDER B E. Abuse by external heating, overcharge and short circuiting of commercial lithium-ion battery cells[J]. Journal of the Electrochemical Society, 2014, 161(10): A1611-A1617. DOI:10.1149/2.0311410jes.

[3] ZHOU Z Z, LI M Y, ZHOU X D, et al. Investigating thermal runaway triggering mechanism of the prismatic lithium iron phosphate battery under thermal abuse[J]. Renewable Energy, 2024, 220: 119674. DOI:10.1016/j.renene.2023.119674.

[4] XING B B, XIAO F Y, KOROGI Y, et al. Direction-dependent mechanical-electrical-thermal responses of large-format prismatic Li-ion battery under mechanical abuse[J]. Journal of Energy Storage, 2021, 43: 103270. DOI:10.1016/j.est.2021.103270.

[5] RICHARDSON R R, IRELAND P T, HOWEY D A. Battery internal temperature estimation by combined impedance and surface

- temperature measurement[J]. *Journal of Power Sources*, 2014, 265: 254-261. DOI:10.1016/j.jpowsour.2014.04.129.
- [6] SHEN P, OUYANG M G, LU L G, 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. DOI:10.1109/TVT.2017.2751613.
- [7] HE H W, XIONG R, ZHANG X W, et al. State-of-charge estimation of the lithium-ion battery using an adaptive extended Kalman filter based on an improved thevenin model[J]. *IEEE Transactions on Vehicular Technology*, 2011, 60(4): 1461-1469. DOI:10.1109/TVT.2011.2132812.
- [8] ZHENG F D, JIANG J C, SUN B X, et al. Temperature dependent power capability estimation of lithium-ion batteries for hybrid electric vehicles[J]. *Energy*, 2016, 113: 64-75. DOI: 10.1016/j.energy.2016.06.010.
- [9] BAO J T, MAO Y, ZHANG Y B, et al. Critical review of temperature prediction for lithium-ion batteries in electric vehicles [J]. *Batteries*, 2024, 10(12): DOI:10.3390/batteries10120421.
- [10] LIU X F, LI Y C, KANG Y Z, et al. An accurate co-estimation of core temperature and state of charge for lithium-ion batteries with electrothermal model[J]. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 2024, 12(1): 231-241. DOI:10.1109/JESTPE.2023.3304754.
- [11] ZHANG C, LI K, DENG J. Real-time estimation of battery internal temperature based on a simplified thermoelectric model[J]. *Journal of Power Sources*, 2016, 302: 146-154. DOI: 10.1016/j.jpowsour.2015.10.052.
- [12] BAO J T, MAO Y, ZHANG Z M, et al. A data-driven-aided thermoelectric equivalent circuit model for accurate temperature prediction of lithium-ion batteries[J]. *International Journal of Energy Research*, 2024, 2024(1): 5544635. DOI: 10.1155/er/5544635.
- [13] HUSSEIN A A. A sensorless surface temperature measurement method for batteries using artificial neural networks[C]//2018 IEEE Energy Conversion Congress and Exposition (ECCE). September 23-27, 2018, Portland, OR, USA. IEEE, 2018: 3560-3564. DOI:10.1109/ECCE.2018.8557926.
- [14] JIANG L, YAN C K, ZHANG X S, et al. Temperature prediction of battery energy storage plant based on EGA-BiLSTM[J]. *Energy Reports*, 2022, 8: 1009-1018. DOI:10.1016/j.egyr.2022.02.195.
- [15] LIU F F, LAN F C, CHEN J Q. Dynamic thermal characteristics of heat pipe via segmented thermal resistance model for electric vehicle battery cooling[J]. *Journal of Power Sources*, 2016, 321: 57-70. DOI:10.1016/j.jpowsour.2016.04.108.
- [16] AMINI A, ÖZDEMİR T, EKICI Ö, et al. A thermal model for Li-ion batteries operating under dynamic conditions[J]. *Applied Thermal Engineering*, 2021, 185: 116338. DOI: 10.1016/j.applthermaleng.2020.116338.
- [17] CHEN L, ZHANG M, DING Y H, et al. Estimation the internal resistance of lithium-ion-battery using a multi-factor dynamic internal resistance model with an error compensation strategy[J]. *Energy Reports*, 2021, 7: 3050-3059. DOI: 10.1016/j.egyr.2021.05.027.
- [18] ZHANG L J, PENG H, NING Z S, et al. Comparative research on RC equivalent circuit models for lithium-ion batteries of electric vehicles[J]. *Applied Sciences*, 2017, 7(10): DOI: 10.3390/app7101002.
- [19] AZUAJE - BERBECÍ B J, ERTAN H B. A model for the prediction of thermal runaway in lithium-ion batteries[J]. *Journal of Energy Storage*, 2024, 90: 111831. DOI:10.1016/j.est.2024.111831.
- [20] 岳永胜, 孙冬, 许爽, 等. 锂离子电池等效电路模型的研究进展[J]. *电池*, 2023, 53(6): 682-686.
- YUE Y S, SUN D, XU S, et al. Research progress in equivalent circuit model for Li-ion battery[J]. *Battery Bimonthly*, 2023, 53(6): 682-686.
- [21] WANG L M, NIU J Y, ZHAO W, et al. Study on electrochemical and thermal characteristics of lithium-ion battery using the electrochemical-thermal coupled model[J]. *International Journal of Energy Research*, 2019, 43(6): 2086-2107. DOI: 10.1002/er.4410.
- [22] 刘岸晖, 甘小燕, 何佩芸, 等. 锂离子电池热模型的研究动态[J]. *电源学报*, 2019, 17(1): 95-103.
- LIU A H, GAN X Y, HE P Y, et al. Progress of research on thermal models of lithium-ion battery[J]. *Journal of Power Supply*, 2019, 17(1): 95-103.
- [23] LIN J Y, LIU X H, LI S, et al. A review on recent progress, challenges and perspective of battery thermal management system[J]. *International Journal of Heat and Mass Transfer*, 2021, 167: 120834. DOI:10.1016/j.ijheatmasstransfer.2020.120834.
- [24] 韩莉慧. 基于双线性变换的非线性发展方程的几类精确解的研究[D]. 呼和浩特: 内蒙古工业大学, 2021.
- HAN L H. Study on some exact solutions of nonlinear evolution equations based on bilinear transformation[D]. Hohhot: Inner Mongolia University of Tehchnology, 2021.
- [25] BERNARDI D, PAWLIKOWSKI E, NEWMAN J. A general energy balance for battery systems[J]. *Journal of the Electrochemical Society*, 1985, 132(1): 5-12. DOI:10.1149/1.2113792.
- [26] LIU Z T, LI C G. Recursive least squares for censored regression [J]. *IEEE Transactions on Signal Processing*, 2017, 65(6): 1565-1579. DOI:10.1109/TSP.2016.2646660.