

储能测试与评价



一种基于不一致性特征融合的电池组健康状态估计方法

齐洪峰¹, 吴祖正², 张珺玮³, 任坤华¹, 张言茹²

(¹中车工业研究院有限公司, 北京 100160; ²北京交通大学, 北京 100044; ³中移能源科技(北京)有限公司, 北京 100044)

摘要: 锂离子电池组健康状态 (state of health, SOH) 的准确估计对于保障电池安全可靠运行至关重要, 本研究提出一种考虑复杂不一致性影响的电池组健康状态估计方法。该方法从电池原始充电时序数据与容量增量曲线中挖掘反映电池组单体不一致性演变规律的特征信息, 结合相关性分析完成冗余特征剔除, 筛选出核心不一致性特征, 构建融合片段充电时序特征与单体不一致性标量特征的电池组健康表征体系。提出了一种 Transformer 编码器与多层感知机相结合的双分支 SOH 估计模型, 实现时序特征与标量特征的有效融合。依托经过实测数据校验、精度可靠的电池组数字孪生仿真平台, 构建了覆盖完整健康区间的仿真样本数据集完成模型训练与初步测试。结果表明, 所提模型在测试集上表现出较高的 SOH 估计精度, 均方根误差小于 1%。进一步在两组不同不一致性、不同健康状态的实测电池组数据上开展了模型迁移验证, SOH 估计绝对误差小于 2%。通过特征消融研究进一步验证了不一致性特征的引入与特征融合策略能够显著提升模型的 SOH 估计精度与可靠性。

关键词: 电池组; 健康状态; 不一致性; 特征融合; 容量增量曲线

doi: 10.19799/j.cnki.2095-4239.2026.0281

中图分类号: TM 911

文献标志码: A

文章编号: 2095-4239 (2026) 08-3280-14

A state of health estimation method for battery packs based on cell inconsistency feature fusion

QI Hongfeng¹, WU Zuzheng², ZHANG Junwei³, REN Kunhua¹, ZHANG Yanru²

(¹CRRC Industrial Research Institute Co., Ltd, Beijing 100160, China; ²Beijing Jiaotong University, Beijing 100044, China; ³China Mobile Energy Technology (Beijing) Co., Ltd, Beijing 100044, China)

Abstract: Accurate state of health (SOH) estimation for lithium-ion battery packs plays an essential role in ensuring safe and reliable operation, particularly under complex inconsistency conditions. This study proposes an SOH estimation method that extracts time-series and statistical features reflecting cell inconsistency from charging time-series data and capacity increment curves. Redundant features are removed through correlation analysis while retaining the core inconsistency features. A dual-branch model based on a Transformer encoder and a multilayer perceptron is then developed to fuse dynamic temporal information with global inconsistency descriptors. To support the training and preliminary testing of the model, a large-scale simulation dataset covering the full battery health range is generated on

收稿日期: 2026-04-02; 修改稿日期: 2026-05-28。

第一作者: 齐洪峰 (1973—), 男, 硕士, 正高级工程师, 研究方向为轨道交通装备产品平台技术, E-mail: qihongfeng@crrecg.cc; 通信作者: 张言茹, 博士, 实验师, 研究方向为动力电池技术, E-mail: yr_zhang@bjtu.edu.cn。

引用本文: 齐洪峰, 吴祖正, 张珺玮, 等. 一种基于不一致性特征融合的电池组健康状态估计方法[J]. 储能科学与技术, 2026, 15(8): 3280-3293.

Citation: QI Hongfeng, WU Zuzheng, ZHANG Junwei, et al. A state of health estimation method for battery packs based on cell inconsistency feature fusion[J]. Energy Storage Science and Technology, 2026, 15(8): 3280-3293.

a battery-pack digital twin and verified against measured data. The proposed method achieves a high SOH estimation accuracy (root mean square error <1%) on the test set. Transfer validation on two measured battery packs with different inconsistency and health states shows absolute SOH estimation errors below 2%. Ablation results further demonstrate that the inconsistency features and fusion strategy significantly improve the SOH estimation accuracy and robustness.

Keywords: battery pack; state of health; inconsistency; feature fusion; incremental capacity curve

锂离子电池因其高能量密度、长循环寿命和低自放电率等优势，已成为电动汽车、大规模储能系统及轨道交通储能的核心储能元件。确保电池在整个生命周期内安全、可靠、高效地运行，是推动相关产业发展的关键。然而，电池在重复充放电使用过程中，其内部会发生不可逆的电化学副反应，如固体电解质界面膜的持续增长、活性锂的损失、电极材料的结构降解等，导致电池性能逐渐衰退^[1-3]。此外，为满足实际应用中的功率和能量需求，通常将多个电池串并联成组使用，而组内单体间性能存在初始不一致性，且随着电池老化，单体间不一致性逐渐劣化，进一步加剧电池组性能的衰退^[4-6]。电池健康状态（state of health, SOH）作为量化电池性能衰退的核心指标，是电池管理系统（battery management system, BMS）进行安全监测、均衡控制及健康管理的重要依据。准确的 SOH 估计对维持电池长期安全稳定运行、优化充放电管理策略及延长电池使用寿命具有至关重要的工程与科学意义^[7-9]。探究高精度、强泛化能力的 SOH 估计方法，已成为学术界和工业界共同关注的前沿课题。

现有的电池 SOH 估计方法大致可分为基于模型的方法、数据驱动的方法以及数据模型结合的方法^[9]。基于模型的方法通过建立能够描述电池外特性表征的物理或电化学模型，并结合相关滤波算法，实现对电池状态的动态估计^[10]。此类方法估计精度依赖于模型参数的准确性，且在电池组层面进行参数在线辨识面临较大的计算压力。数据驱动方法不依赖于复杂的内部机理模型，而是从可观测数据（如电压、电流、温度）中自动学习老化特征与 SOH 之间的隐藏映射关系。早期研究多采用支持向量机、相关向量机等浅层模型，近年来，随着算力的提升和数据量的积累，深度学习方法展现出显著优势^[11-13]。

单纯的数据驱动模型在泛化能力与物理可解释性上存在不足。为此，融合神经网络与物理模型的混合方法近年来备受关注^[14]。文献[15]将电池容量增量曲线特征与容量衰减之间的变化关系嵌入神经网络实现物理约束，提高电池 SOH 估计准确性和可解释性。文献[16]则从物理学、电化学、统计学等层面提取了电池老化特征库，并自动筛选特征，构建特征空间，在多种机器学习模型中实现准确的 SOH 估计。

当前关于电池 SOH 的研究多聚焦于单体层面，而在电池组层面则面临更为复杂的系统性和成倍增长的计算量。部分研究将电池组视为整体，或仅选取代表性单体进行估计。然而，此类方法虽降低了计算复杂度，却忽略了组内不一致性对整体性能的影响。近年来，不一致性对电池组健康状态估计的影响日益受到重视^[17-18]。文献[19]通过电压差异刻画静态与动态不一致性，从而更准确捕捉单体状态变化。文献[20]将不一致性归纳为 4 种类型，并基于代表性单体构建 SOH 估计公式。文献[21]则借助“平均-差异”模型，通过电压差异跟踪实现 SOH 估计。然而，数据驱动方法在电池组层面应用时面临样本稀缺的挑战：电池组测试成本高、周期长，获取高质量实车数据难度大。如何生成具有物理意义的电池组数据以实现数据增强并支撑数据驱动方法应用，是有待解决的关键问题。

此外，现有研究多集中于电池 SOH 估计算法层面的优化，而对 SOH 指标的探讨相对较少。传统方法多以电池容量衰减或内阻增加作为健康状态指标，但实际场景中用户更关注电池的续航能力，而电池可用能量是最直接体现续航的关键参数。因此，以能量为基础定义 SOH 更具工程价值。文献[22]将 SOH 定义为当前最大可用能量与额定能量的比值，综合考虑容量与内阻退化不一致性；文献

[23]将SOH表现为整组最大可用能量变化,并基于模型参数辨识实现精准预测。

针对上文总结的不足,提出了一种基于不一致性特征融合的电池组健康状态估计方法,其创新和贡献如下:①从单体电压曲线中提取了反映单体性能差异的特征,并通过相关性分析进行特征筛选,构建不一致性标量特征与统计时序特征融合的电池组健康特征,实现不一致性对电池组SOH影响的有效映射;②基于Transformer编码器和多层感知机分别处理不同类型的特征,实现电池组SOH的精确估计,相较于单类型特征实现了更高的精度和鲁棒性;③搭建了融合电池组等效电路模型与不一致性表征模型的电池组数字孪生模型,并通过不一致性参数量化方式生成多健康状态电池组样本实现数据增强,依托仿真数据训练的模型在两组真实测试样本上取得了良好的迁移效果。

本研究各部分内容如下:第1部分介绍了本研究对电池组健康状态的定义;第2部分介绍了电池组测试平台与孪生仿真平台的搭建以及数据样本的生成;第3部分介绍了电池组不一致性特征的提取及健康状态融合特征的构建;第4部分介绍了基于融合特征的神经网络模型架构;第5部分对结果进行了充分讨论;第6部分给出结论。

1 电池组健康状态定义

在电池健康状态评估中,通常采用容量的衰减和内阻的增大作为关键指标^[24]。然而,从实际应用的角度来看,能量这一参数能够更全面地反映电池在实际工况下的输出能力,因而更具有工程参考价值。电池组最大可用能量可以表示为:

$$E_{MAE} = \sum_{i=1}^n \int_{SOC_{low}^i}^{SOC_{up}^i} U_{OCV}^i Q_i dSOC \quad (1)$$

式中, SOC_{up}^i 和 SOC_{low}^i 为当电池组内某只单体到达下限截止电压和上限截止电压时单体*i*的剩余荷电状态; U_{OCV}^i 为单体开路电压,可表示为SOC的映射函数; Q_i 为单体完整容量; E_{MAE} 反映了电池组内单体容量差异、OCV差异以及单体间不一致性带来的能量损失,相较于容量参数更直接体现了电池系统续航性能,因此本研究基于最大可用能量参数对电池组健康状态进行定义:

$$SOH = \frac{E_{MAE, old}}{E_{MAE, fresh}} \quad (2)$$

式中, $E_{MAE, old}$ 为当前状态下电池组最大可用能量; $E_{MAE, fresh}$ 为初始出厂状态电池组最大可用能量,本研究中假设初始出厂状态下各单体容量与SOC保持一致,则初始最大可用能量可以表示为:

$$E_{MAE, fresh} = nQ_{rate} \int_0^{100} U_{OCV} dSOC \quad (3)$$

式中, Q_{rate} 为单体电池额定容量。

2 基于数字孪生的电池组数据集构建

2.1 串联电池组测试平台

在实验室环境下搭建了由60个串联单体组成的电池组实验平台,每个单体由若干个18650型圆柱电芯并联构成,旨在通过调节并联电芯数量以模拟串联单体之间的容量差异。此外,可通过单体独立充放电调整其SOC差异,实现对单体不一致性的定量调控。测试平台如图1所示,所有18650电芯均选自同一型号和批次,以忽略并联电芯间微小差异对实验的干扰。本研究中定义标准单体由48个小电芯并联构成,对应额定容量为124.8 Ah。采用Maccor 5 V-200 A电池充放电测试系统对标准单体开展性能测试,以及对串联单体进行SOC调节;采用Arbin RBT-EV测试设备用于开展电池组充放电测试,电压范围5~650 V,最大电流300 A。电池组测试在步入式温箱中进行,并配合风扇散热,以确保组内单体温度一致性。

2.2 电池组数字孪生仿真模型

2.2.1 电池组物理模型

考虑到电池组老化受多源驱动因素影响具有随机性,单一的老化路径往往缺乏代表性,且广泛获取不同健康状态下的电池组实验样本面临成本高、周期长的问题^[25]。本研究构建了电池组数字孪生仿真模型,基于电池组测试平台获取电池基本模型参数,并构建与之具有相同成组架构的电池组物理仿真模型,通过对单体参数进行量化配置,实现任意健康状态电池组的可控模拟。所搭建的电池组模型架构如图2所示,考虑仿真精度与仿真效率之间的平衡,选用一阶RC模型作为串联单体的基本模型,则电池组端电压可以表示为:

$$U_{pack}(t) = \sum_{i=1}^n U_0^i(t) = \sum_{i=1}^n [U_{OCV}^i(t) - I(t)R_0^i(t) - U_p^i(t)] \quad (4)$$

式中, U_{pack} 为电池组总电压; U_0^i 为单体端电压; I 为电流; U_{OCV}^i 为单体开路电压; R_0^i 为欧姆内阻; U_p^i 为RC网络的极化电压。每个单体的状态变




图 1 电池组测试及仿真平台

Fig. 1 Battery pack testing and simulation platform

量遵循式(5)。

$$\begin{cases} \frac{dU_p^i(t)}{dt} = \frac{I(t)}{C_p^i} - \frac{U_p^i(t)}{R_p^i C_p^i} \\ \frac{dSOC_i}{dt} = -\frac{I(t)}{Q_i} \end{cases} \quad (5)$$

式中, R_p^i 和 C_p^i 分别为极化内阻和极化电容; SOC_i 和 Q_i 为单体 i 的荷电状态和容量。采用欧拉法离散化处理后, 单体极化电压与 SOC 按时间步长 Δt 进行更新:

$$U_p^i(k+1) = U_p^i(k) \cdot \exp\left(\frac{-\Delta t}{R_p^i C_p^i}\right) + I(k) \cdot R_p^i \cdot \left(1 - \exp\left(\frac{-\Delta t}{R_p^i C_p^i}\right)\right) \quad (6)$$

$$SOC_i(k+1) = SOC_i(k) - \frac{I(k) \cdot \Delta t}{Q_i} \quad (7)$$

电池组总电压离散形式表示为:

$$U_{pack}(k) = \sum_{i=1}^n \{U_{ocv}^i[SOC(k)] - I(k) \cdot R_0^i - U_p^i(k)\} \quad (8)$$




图 2 电池组等效电路模型

Fig. 2 Equivalent circuit model of battery pack

2.2.2 不一致性表征模型

单体不一致性是影响电池组健康状态的关键因素, 本研究围绕单体容量、内阻、SOC 三个对电池组性能影响突出的参数, 构建不一致性表征模型, 并通过不一致性参数的量化配置实现对电池组健康状态的模拟。

多元高斯分布模型常用于描述多个随机变量之间的联合概率特性, 该模型假设各随机变量均服从正态分布, 并且变量之间存在一定相关性。采用多元高斯分布模型对单体不一致性参数进行建模, 假设单体容量、SOC 与内阻服从三元高斯联合分布:

$$\mathbf{X} = [Q, SOC, \Delta R]^T \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \quad (9)$$

概率密度函数表示为:

$$f(\mathbf{X}) = \frac{1}{(2\pi)^{n/2} |\boldsymbol{\Sigma}|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{X} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{X} - \boldsymbol{\mu})\right] \quad (10)$$

式中, $\boldsymbol{\mu}$ 为均值向量, 用于描述每个随机变量的期望值, 如式(11)所示; $\boldsymbol{\Sigma}$ 为协方差矩阵, 用于描述每个变量的方差及变量间的协方差, 如式(12)所示。

$$\boldsymbol{\mu} = [\mu_Q, \mu_{SOC}, \mu_{\Delta R}]^T \quad (11)$$

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_Q^2 & \rho_1 \sigma_Q \sigma_{SOC} & \rho_2 \sigma_Q \sigma_{\Delta R} \\ \rho_1 \sigma_Q \sigma_{SOC} & \sigma_{SOC}^2 & \rho_3 \sigma_{SOC} \sigma_{\Delta R} \\ \rho_2 \sigma_Q \sigma_{\Delta R} & \rho_3 \sigma_{SOC} \sigma_{\Delta R} & \sigma_{\Delta R}^2 \end{bmatrix} \quad (12)$$

式中, σ_Q 、 σ_{SOC} 和 $\sigma_{\Delta R}$ 为单体容量、SOC和内阻的标准差; ρ_1 、 ρ_2 和 ρ_3 分别为单体容量与SOC、容量与内阻、SOC与内阻之间的相关系数。

通过灵活配置各单体参数的分布均值、标准差及相关系数,能够精确描述单体参数在不同健康状态下的统计特性及其相关性,实现对不同健康状态下电池组不一致性特性的仿真模拟。

2.2.3 电池组仿真模型精度检验

为评估所构建的电池组孪生仿真模型在实际应用中的可行性与可靠性,通过实验测试对模型仿真精度进行了系统性验证。图3展示了在0.5 C倍率下电池组恒流充放电过程中的单体电压仿真与实测对比,以及平均单体电压误差曲线。可以看出,在充放电初期阶段,由于电池极化建立的不稳定性,仿真误差稍高,其他阶段仿真模型整体能够较好地还原恒流充放电下的单体电压变化,平均单体电压误差基本保持在5 mV以内。对比分析表明,所构建的电池组孪生仿真模型能够有效描述电池单体电压输出特性,为后续仿真分析及多健康状态数据样本的生成提供了可靠的模型基础。

2.3 多健康状态电池组样本生成

依托所搭建的串联电池组等效电路模型以及表征单体不一致性的多元联合分布模型,通过对单体参数分布均值和标准差进行量化配置,仿真生成了涵盖不同不一致性水平的高质量数据集。采用容量保有率反映单体容量损失情况,如式(13)所示。

$$Q_{rate}^i = \frac{Q_i}{Q_{nominal}} \quad (13)$$

式中, Q_{rate}^i 为容量保有率; Q_i 为电池当前容量; $Q_{nominal}$ 为电池额定容量。

采用内阻增长率反映单体内阻老化情况,如式(14)所示。

$$\Delta R_{rate}^i = \frac{\Delta R_i}{R_{nominal}} \quad (14)$$

式中, ΔR_{rate}^i 为内阻增长率; ΔR_i 为内阻增量,反映相较于新电池的内阻增长情况; $R_{nominal}$ 为电池额定内阻。

对于单体容量、SOC和内阻三种参数,依次设置了不一致性边界条件,如式(15)所示。单体容量保有率分布在80%~100%区间,起始SOC分布在0%~20%区间,内阻增长率则分布在0%~50%区间。




图3 电池组仿真模型精度验证

Fig. 3 Accuracy verification of battery pack simulation model

$$\begin{cases} 80\% < Q_{rate}^i < 100\% \\ 0\% < SOC_i < 20\%, i = 1, 2 \dots n \\ 0\% < \Delta R_{rate}^i < 50\% \end{cases} \quad (15)$$

在不一致性参数分布边界内,采用蒙特卡罗抽样方法对3种单体参数通过均值与标准差进行随机配置和组合,从而保证生成数据在参数空间内具备良好的分布覆盖性,共生成5000个电池组样本。

3 电池组不一致性特征提取

3.1 单体不一致性的表征分析

电池外电压是运行过程中较易获取的监测数据,其动态变化趋势更与电池健康状态密切相关,因此常被用作电池健康评估所依赖的关键数据。单体不一致性是影响电池组SOH的核心因素,本研究对外电压特性曲线进行解析,基于2.3节中仿真

生成的多健康状态电池组样本集，探究单体参数不一致性在外电压曲线上的差异性表征。考虑到实际应用场景下电池放电工况具有随机性，围绕恒流充电电压曲线开展分析。此外，由于电池电压区间窄，且平台效应会削弱电压变化特征，因此采用数学变换对电压曲线进行处理以实现特征增强，如容量增量 (incremental capacity, IC) 分析，将电压的微小变化转化为显著的峰谷特征，如式(16)所示。

$$IC_{i,k} \approx \frac{Q_{i,k+1} - Q_{i,k}}{V_{i,k+1} - V_{i,k}}, k = 1, 2 \dots N-1 \quad (16)$$

式中， $Q_{i,k}$ 和 $V_{i,k}$ 分别为单体 i 在第 k 个采样点的累积充电容量及对应外电压； N 为数据点总数。采样频率、噪声等因素可能影响 IC 曲线的质量，采用 Savitzky-Golay 滤波器对原始 IC 曲线进行平滑滤波处理，该平滑方法在有效抑制高频噪声的同时，可最大程度保留 IC 曲线峰谷特征与波形形态，避免传统滤波导致的特征畸变。

从单体电压曲线及 IC 曲线上提取了 11 个特征参数，如图 4 所示，包括单体 IC 曲线主峰水平位置




图 4 电池特征提取

Fig. 4 Schematic diagram of battery feature extraction

的最大值、最小值、平均值和极差，IC 曲线主峰幅值的最大值、最小值、平均值和极差，以及充电起始、中间、截止时刻单体电压的分布极差。详细的特征描述及命名见表 1。

依托仿真生成的不同健康状态电池组样本集，

表 1 特征参数说明

Table 1 Characteristic parameter description

特征参数	描述
ICx_max	最大单体 IC 峰位置
ICx_min	最小单体 IC 峰位置
ICx_mean	平均单体 IC 峰位置
ICx_range	单体 IC 峰位置极差
ICy_max	最大单体 IC 峰值
ICy_min	最小单体 IC 峰值
ICy_mean	平均单体 IC 峰值
ICy_range	单体 IC 峰值极差
Vrange_ini	起始单体电压极差
Vrange_mid	中间单体电压极差
Vrange_end	截止单体电压极差

分析单体不一致性参数与电压特性表征之间的相关关系，并利用 Spearman 相关系数作为相关性判断依据，计算公式如下：

$$\rho = 1 - \frac{6 \sum_{i=1}^n [R(x_i) - R(y_i)]^2}{n(n^2 - 1)} \quad (17)$$

式中， $R(x_i)$ 和 $R(y_i)$ 分别为两个变量的秩次； n 为样本数量。

分析结果如图 5 所示，不一致性参数包括单体容量、SOC 和内阻的分布均值与极差，相关系数大于 0.5 认定为相关性密切。可以看到，单体 IC 曲线主峰峰值的最大值、最小值及平均值都表现出与单体容量分布均值的强正相关，表明随着单体容量分布均值的衰减，单体 IC 主峰峰值呈现整体下降趋势，而单体容量分布极差则与单体间 IC 峰值极差呈现显著相关。类似的，单体内阻分布均值呈现出与 IC 主峰水平位置最大值、最小值及平均值的强相关性，单体内阻分布极差则与 IC 主峰水平位置的极差呈显著正相关。此外，单体 SOC 分布极差与充电起始、中间及截止时刻的单体电压分布范围呈正相关，说明单体 SOC 不一致性对充电过程单体电压的分布离散度有明显影响。

3.2 考虑单体不一致性的电池组健康特征

上述分析表明，在不一致性参数相互耦合的情况下，各不一致性参数在电池外电压上表现出差异性表征：容量不一致性主要表现为对 IC 曲线“峰值”特征的影响，内阻不一致性则主导了 IC 峰“水平位置”的偏移，而 SOC 不一致性则主要体现在单体电压在时间维度上的分布特性。基于此，提取了考虑不一致性的健康特征，用作后续电池组健




图5 不一致性参数与电压特性的相关性分析

Fig. 5 Correlation analysis between inconsistency parameters and voltage characteristics

康状态估计模型的输入。考虑到部分特征参数之间的同质性，如IC峰值最大值、最小值与平均值对容量不一致的影响具有同质效果，因此仅保留平均值作为代表特征。提取了如式(18)所示的4个关键不一致标量特征，包括单体IC峰值的平均值和极差、IC峰位置的平均值和极差。此外，提取片段充电窗口的时间序列特征，包括最大单体电压、最小单体电压、平均单体电压、充电电流，如式(19)所示。

$$F_{\text{scalar}} = [\text{ICx_mean}, \text{ICx_range}, \text{ICy_mean}, \text{ICy_range}] \quad (18)$$

$$F_{\text{seq}} = \begin{bmatrix} V_{\min,1} & V_{\max,1} & V_{\text{mean},1} & I_1 \\ V_{\min,2} & V_{\max,2} & V_{\text{mean},2} & I_2 \\ \vdots & \vdots & \vdots & \vdots \\ V_{\min,L} & V_{\max,L} & V_{\text{mean},L} & I_L \end{bmatrix} \quad (19)$$

4 基于特征融合的电池组SOH估计模型

依托上一节中筛选提取的反映电池组不一致性的健康状态特征，构建了双分支神经网络模型，针对不同类型特征分别开展深层信息挖掘，并通过特征融合机制实现精准的电池组SOH回归估计。模型整体架构如图6所示，主要包含三个部分：基于Transformer编码器从电池充电原始电压电流时间序列中捕获健康特征；基于多层感知机（multilayer perceptron, MLP）学习不一致性标量特征与电池

组SOH之间的非线性映射；将两个分支提取的高维特征拼接，并通过全连接网络回归实现电池组SOH估计。




图6 特征融合神经网络模型架构

Fig. 6 Feature fusion neural network architecture

4.1 基于Transformer的序列特征提取

Transformer是一种主要基于自注意力机制的深度学习模型架构，能够进行高效的并行计算，并能够有效处理长距离依赖问题，在处理时序信息方面具有显著优势。首先，通过一个线性投影层将原始时间序列每个时间步的特征投影到高维空间，以增强模型的表达能力：

$$X_0 = F_{\text{seq}} \cdot W + b \quad (20)$$

式中， F_{seq} 为原始时序特征； X_0 为投影后的序

列； $\mathbf{W}$ 和 $\mathbf{b}$ 分别为权重向量和偏置。鉴于充电过程具有时间顺序特性，模型引入了可学习位置编码以注入顺序信息：

$$\mathbf{X}'_0 = \mathbf{X}_0 + \mathbf{P} \quad (21)$$

式中， $\mathbf{P}$ 为位置编码矩阵； $\mathbf{X}'_0$ 为编码后序列。

添加位置信息后的序列被送入由 2 个相同的 Transformer 编码层堆叠而成的编码器。每一层都包含一个多头自注意力（multi-head self-attention, MSA）机制和一个前馈网络（feedforward network, FFN），并均采用残差连接和层归一化（LayerNorm）来稳定训练过程。

$$\begin{cases} \mathbf{X}'_l = \text{LayerNorm}[\text{MSA}(\mathbf{X}_{l-1}) + \mathbf{X}_{l-1}] \\ \mathbf{X}_l = \text{LayerNorm}[\text{FFN}(\mathbf{X}'_l) + \mathbf{X}'_l] \end{cases} \quad (22)$$

式中， $\mathbf{X}_l$ 和 $\mathbf{X}_{l-1}$ 分别为第 l 层和第 $l-1$ 层输出。

多头自注意力机制由多个自注意力模块组成，允许模型同时关注序列中不同位置的信息，其主要架构如图 7 所示。对于每个自注意力头 i ，将输入 $\mathbf{X}$ 通过线性变换投影到查询（ $\mathbf{Q}$ ）、键（ $\mathbf{K}$ ）和值（ $\mathbf{V}$ ）空间：




图 7 多头自注意力机制

Fig. 7 Multi-head self-attention mechanism

$$\mathbf{Q}_i = \mathbf{X}\mathbf{W}_i^Q, \mathbf{K}_i = \mathbf{X}\mathbf{W}_i^K, \mathbf{V}_i = \mathbf{X}\mathbf{W}_i^V \quad (23)$$

式中， $\mathbf{W}_i^Q$ 、 $\mathbf{W}_i^K$ 、 $\mathbf{W}_i^V$ 为三个独立的权重矩阵。在每个头上并行计算缩放点积注意力：

$$\text{head}_i = \text{Attention}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) = \text{softmax}\left(\frac{\mathbf{Q}_i\mathbf{K}_i^T}{\sqrt{d_k}}\right)\mathbf{V}_i \quad (24)$$

式中， d_k 为每个头的维度。将所有头的输出向量拼接起来并经过一个线性投影整合所有信息：

$$\text{MultiHead} = \text{concat}(\text{head}_1, \dots, \text{head}_h)\mathbf{W}^O \quad (25)$$

式中， h 表示注意力头的个数，即并行计算的独立子空间的数量； $\mathbf{W}^O$ 表示线性投影层。

前馈网络是一个包含两层线性变换和 ReLU 激

活函数的全连接网络，用于对每个位置的特征进行非线性变换：

$$\text{FFN}(\mathbf{X}) = \max(0, \mathbf{X}\mathbf{W}_1 + \mathbf{b}_1)\mathbf{W}_2 + \mathbf{b}_2 \quad (26)$$

经过两层编码后，对所得到的特征序列进行自适应平均池化得到输出特征。

4.2 基于 MLP 的标量特征提取及特征融合

为充分利用电池组不一致性表征的先验知识，设置了一个轻量级的 MLP 模型分支来处理手动提取的不一致性标量特征。模型由两个隐藏层组成，每个隐藏层包含一个全连接网络及激活函数 ReLU，通过非线性变换将低维标量特征映射到与时序特征兼容的高维空间。

将两个分支的输出特征向量进行拼接，形成融合特征向量，融合特征通过由两层全连接网络构成的回归模型得到最终的输出电池组 SOH。为提高模型泛化能力，避免发生过拟合，在训练过程中引入了 Dropout 正则化。此外，在模型训练阶段，采用均方误差（mean squared error, MSE）作为损失函数以优化模型参数：

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

式中， n 为样本个数； $\hat{y}_i$ 和 y_i 分别为第 i 个样本的估计值和真实值。

4.3 模型超参数及评价指标

模型的超参数配置是影响其性能与泛化能力的关键因素。通过综合考虑任务复杂度、数据体量及计算效率，设定了模型各组成部分的超参数：注意力头数为 8；编码器层数为 2；Dropout 为 0.1；批量大小为 64；学习率为 0.0001。将数据样本按比例划分为训练集、验证集和测试集，训练集用于模型的参数更新，验证集则用于监控模型的泛化能力。测试集用于检测模型在新数据上的表现。为优化模型训练过程并防止过拟合，采用了基于早停机制的正则化策略，其核心思想是在训练过程中持续评估模型在独立验证集上的性能，在验证误差达到最低点时终止训练，而非简单地给定训练周期，此时的模型参数被认为在新数据上的表现最好。这里定义当验证损失连续 5 个周期没有降低时，停止训练并保存当前模型参数。

对于电池组健康状态估计结果的评价指标，选取了平均绝对误差（mean absolute error, MAE）和均方根误差（root mean squared error, RMSE）

作为核心评价指标。这两个指标从不同角度衡量模型预测值与真实值之间的偏差，为全面比较模型性能提供了可靠依据。两指标定义如下：

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (28)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (29)$$

5 结果与讨论

为系统评估所提模型的性能，讨论了模型在测试集上的结果，并与多种基线模型对比分析，以验证所提模型的有效性。此外，通过消融分析进一步剖析了模型中关键不一致性特征的贡献，以验证所提模型特征选取和结构设计的合理性。最后，基于实际测试的电池组样本，验证了模型在真实数据上的迁移效果。

5.1 电池组样本数据

所用的数据包含仿真样本和实测样本两方面，基于2.2小节中构建的经实测数据校验、精度可靠的电池组数字孪生仿真模型，通过对单体参数分布的量化配置，生成了5000组SOH在70%~100%区间的仿真电池组样本，其SOH分布如图8所示，并基于该仿真样本数据集划分训练集和测试集，对模型性能开展分析。此外，依托2.1小节搭建的电池组测试平台，通过调整并联电芯数量、充放电调节单体SOC构建不一致性状态，获取了两组健康状态分别为85.64%、80%的电池组实测样本，用于检验模型在实测样本上的迁移效果。

5.2 不同训练样本比例下的估计结果

首先对比了在不同训练样本比例的情况下模型对电池组健康状态的估计结果，以评估所提模型在小样本条件下对数据特征的利用效率。对仿真生成




图8 仿真样本数据集SOH分布

Fig. 8 SOH distribution of simulated sample dataset

的多健康状态电池组样本依次设置了3种数据集划分比例：训练集分别占比30%、50%、70%。图9展示了所构建模型在随机抽取的不同占比训练集上进行训练后，在相同测试集上的电池组SOH估计值与真实值的对比结果，按照样本SOH从高到低降序排列，估计绝对误差分布情况如图10所示，估计误差指标见表2。结果表明，仅依赖30%的数据作为训练集时，模型便能够实现较好的估计性能，在测试集上估计结果MAE为0.78%，RMSE为1.09%。此外，随着训练集占比的增加，模型估计结果绝对误差呈现降低趋势，在训练集占比70%时，模型在测试集上的MAE和RMSE分别降到了0.65%和0.86%。这表明所提出的模型仅依赖少量数据样本就能够实现健康特征的有效捕捉，实现精准的电池组SOH估计，且在不同训练样本比例下均能保持稳定的性能，具有良好的应用优势。

5.3 不同窗口长度下的估计结果

在对电池组时间序列数据进行特征提取时，数据的窗口长度是影响模型性能的一个关键因素。分




图9 不同训练样本比例下电池组SOH估计结果

Fig. 9 Battery pack SOH estimation results under different training sample ratios




图 10 不同训练样本比例下电池组 SOH 估计误差
Fig. 10 Battery pack SOH estimation errors under different training sample ratios

表 2 不同训练样本比例下电池组 SOH 估计评价指标
Table 2 Battery pack SOH estimation indicators under different training sample ratios

训练样本比例/%	MAE	RMSE
30	0.78	1.09
50	0.68	0.92
70	0.65	0.86

别选取了窗口长度为 $L=200$ 、250、300 的时序特征输入，在保持其他超参数与训练条件一致的情况下，对模型进行了训练与评估。图 11 展示了在不同窗口长度下，模型在测试集上的估计结果，估计误差分布情况如图 12 所示，表 3 给出了模型性能指标对比。结果表明，当窗口长度设置较短时（如 $L=200$ ），模型性能相对较差，MAE 和 RMSE 分别为 0.79% 和 1.15%。这主要是由于有限的序列长度无法为模型提供足够的特征信息以捕捉电池组老化过程中的典型变化模式，导致其对电池组老化趋势的估计能力不足，从而产生了较高的估计误差。当窗口长度增加至 $L=250$ 时，模型性能得到显著提升，MAE 和 RMSE 分别为 0.65% 和 0.86%。这表明更长的序列数据为模型提供了更丰富的特征信息，使其能够更准确地识别电池组 SOH 变化的规律。当窗口长度进一步增加至 $L=300$ 时，模型性能并未表现出显著提升，反而出现了轻微下降（RMSE=0.9），这可能源于随着序列长度的增加，模型需要处理的序列内部依赖关系呈指数级复杂化，对训练效率和模型容量提出了更高要求，在固定模型架构下可能导致对训练数据集的过拟合，从而损害其泛化能力，对比结果侧面验证了确定最佳输入窗口长度的重要性，最终选取窗口长度 $L=250$ 的数据片段作为




图 11 不同时序特征窗口长度下电池组 SOH 估计结果
Fig. 11 Battery pack SOH estimation results under different feature window lengths




图 12 不同时序特征窗口长度下电池组 SOH 估计误差
Fig. 12 Battery pack SOH estimation errors under different feature window lengths

模型中的时序特征输入。

5.4 特征消融分析及模型对比

为进一步评估所提出的不一致性标量特征与时序特征融合机制的有效性，设计并进行了模型结构的消融研究。其核心思想在于通过构建简化模型变

表3 不同时序特征窗口长度电池组SOH估计评价指标

Table 3 Battery pack SOH estimation indicators under different feature window lengths

时序特征窗口长度	MAE	RMSE
200	0.79	1.15
250	0.65	0.86
300	0.63	0.9

体,在相同的训练与测试集上对比其性能,从而独立出特征融合的贡献。此消融研究设计了以下两个对比模型:对比模型A移除所提取的电池组不一致性标量特征分支,仅以时序特征作为输入,并采用Transformer编码器进行特征编码后直接接入全连接层输出SOH估计。对比模型B移除时序特征提取分支,仅保留不一致性标量特征进行电池组SOH估计。融合特征模型即所提出的模型架构,同时处理时序特征与不一致性标量特征,并进行深度融合。此外,为验证所构建的模型的性能优势,设置两组主流基线模型开展横向对比。其中,对比模型C采用经典长短期记忆网络(long short-term

memory, LSTM)用于提取电池时序特征,对比模型D则选用时间卷积网络(temporal convolutional network, TCN)完成时序特征提取。所有模型均保持其核心超参数一致,并采用相同的训练策略和数据集以确保比较的公平性。图13和图14展示了不同模型在测试集上的估计结果和误差分布,表4给出了相应的性能指标。结果表明,单独的时序特征或不一致性标量特征在对电池组的健康状态解析上均存在局限,最大估计绝对误差超过5%,RMSE分别达到2.04%和3.05%。所搭建的融合特征模型则取得了较为显著的优异性能,其RMSE和MAE均显著低于任一对比特征模型。这一结果清晰地验证了不一致性特征的引入以及特征融合策略的提出对提升电池组SOH估计精度的有效性。作为主流时序模型,LSTM模型和TCN模型均实现了较好的预测效果,估计结果RMSE分别为1.81%和1.56%,但本模型整体表现出更优的适应性与估计精度,整体性能优于两组基线模型。




图13 不同模型下电池组SOH估计结果

Fig. 13 Battery pack SOH estimation results for different models

5.5 实测电池组数据迁移验证

为进一步检验在仿真数据集上训练的模型在真实测试数据样本上的迁移效果,基于2.1小节搭建的串联电池组测试平台,开展了两组具有不同不一致性参数配置的电池组充放电测试,并将训练好的

模型应用于实测电池组样本,以评估其健康状态。相较于孪生仿真平台生成的纯净仿真样本,实测数据能够真实反映电池的老化行为与外特性输出,但往往包含了噪声的影响,对模型的鲁棒性和泛化能力提出了更高要求。两组电池组的测试结果如




图 14 不同模型下电池组 SOH 估计误差
Fig. 14 Battery pack SOH estimation errors for different models

表 4 不同模型下电池组 SOH 估计评价指标
Table 4 Battery pack SOH estimation indicators for different models

模型	MAE/%	RMSE/%
融合特征模型	0.65	0.86
对比模型 A	1.64	2.04
对比模型 B	2.55	3.05
对比模型 C	1.48	1.81
对比模型 D	1.25	1.56

图 15 所示。电池组一真实 SOH 为 85.64%，模型估计结果为 85.87%，绝对误差为 0.23%。电池组二的单体不一致性更为严重，电池组 SOH 仅为 80%，模型估计结果为 81.59%，绝对误差为 1.59%。测试结果表明，基于仿真数据样本所训练的模型不仅在仿真测试集上表现出较好的精度，在两组真实的电池组测试数据上同样保持了稳定的性能输出，误差保持在 2% 以内。




图 15 实测电池组样本 SOH 估计结果
Fig. 15 Battery pack SOH estimation results of real test samples

6 结 论

针对电池组 SOH 估计受到复杂单体不一致性影响的关键问题，提出一种基于不一致性特征融合的电池组 SOH 估计方法。首先基于所搭建的电池组数字孪生仿真模型对电池不一致性的外特性表征开展了研究，并通过相关性分析提取出反映单体不一致性的关键时序特征与统计特征。采用 Transformer 编码器与多层感知机构成双分支模型，实现不同类型特征的多源有效融合，对电池组 SOH 进行精确估计。基于数字孪生平台仿真数据的训练及实测数据的迁移验证结果表明，所提模型不仅在仿真测试集上实现了 RMSE 低于 1% 的高精度估计，在两组真实电池组样本上也表现出良好的迁移应用效果，绝对误差小于 2%。通过消融研究明确了特征融合策略的必要性与有效性，不一致性特征的引入显著提升了模型的估计精度和稳定性。所提方法仅依托片段充电数据实现高精度 SOH 估算，能有效适配实车车载终端数据采集有限的应用场景，且融合了电池时序退化特征与组内不一致性标量特征，弥补了传统单一特征建模难以表征电池组差异化老化规律的不足，能够为电动汽车续航校准、电池安全运维提供有力的技术支撑。

参 考 文 献

[1] 董明, 李晓枫, 熊锦晨, 等. 基于自放电阻抗变化的锂电池存储容量衰减评估技术[J]. 中国电机工程学报, 2025, 45(3): 1052-1062. DOI: 10.13334/j.0258-8013.pcsee.231788.
DONG M, LI X F, XIONG J C, et al. Evaluation of lithium battery storage capacity degradation based on self-discharge impedance change[J]. Proceedings of the CSEE, 2025, 45(3): 1052-1062. DOI: 10.13334/j.0258-8013.pcsee.231788.

[2] 王德顺, 薛金花, 魏海坤, 等. 磷酸铁锂电池模组老化行为[J]. 科学技术与工程, 2022, 22(19): 8562-8567. DOI: 10.3969/j.issn.1671-1815.2022.19.053.
WANG D S, XUE J H, WEI H K, et al. Aging behavior of lithium iron phosphate battery modules[J]. Science Technology and Engineering, 2022, 22(19): 8562-8567. DOI: 10.3969/j.issn.1671-1815.2022.19.053.

[3] 袁梓茵, 严晓, 杨涛. 老化锂电池模组关键电池性能参数的量化分析[J]. 储能科学与技术, 2022, 11(1): 221-227.
YUAN Z H, YAN X, YANG T. Quantitative analysis of key battery performance parameters of aging lithium battery module[J]. Energy Storage Science and Technology, 2022, 11(1): 221-227.

[4] 刘璐, 牛萌, 郑伟杰, 等. 考虑内部参数不一致性的储能系统用锂电池组建模[J]. 电力系统自动化, 2021, 45(19): 15-23. DOI: 10.7500/

- AEPS20210322002.
- LIU L, NIU M, ZHENG W J, et al. Modeling of lithium-ion battery packs for energy storage system considering inconsistency of internal battery parameters[J]. *Automation of Electric Power Systems*, 2021, 45(19): 15-23. DOI: 10.7500/AEPS20210322002.
- [5] 吴凤和, 柴海宁, 章正柱, 等. 基于自适应LTTB与DTW-DBA-means的动力电池组不一致性评估方法[J]. *计量学报*, 2024, 45(6): 890-898.
- WU F H, CHAI H N, ZHANG Z Z, et al. An inconsistency assessment method for power battery pack based on adaptive LTTB and DTW-DBA-means[J]. *Acta Metrologica Sinica*, 2024, 45(6): 890-898.
- [6] 张腾, 常国峰. 基于单体特征参数差异的电池组热特性和热一致性研究[J]. *储能科学与技术*, 2025, 14(8): 3194-3206. DOI: 10.19799/j.cnki.2095-4239.2025.0127.
- ZHANG T, CHANG G F. Thermal characterization and thermal consistency study of battery packs based on differences in monomer characteristic parameters[J]. *Energy Storage Science and Technology*, 2025, 14(8): 3194-3206. DOI: 10.19799/j.cnki.2095-4239.2025.0127.
- [7] 杨思嘉. 电动汽车动力电池组健康状态评估及梯次利用分选应用研究[D]. 北京: 北京交通大学, 2024.
- YANG S J. Research on state of health evaluation and echelon utilization sorting application of power battery packs for electric vehicles[D]. Beijing: Beijing Jiaotong University, 2024.
- [8] 李卓昊, 石琼林, 王康丽, 等. 锂离子电池健康状态估计方法研究现状与展望[J]. *电力系统自动化*, 2024, 48(20): 109-129. DOI: 10.7500/AEPS20231221006.
- LI Z H, SHI Q L, WANG K L, et al. Research status and prospects of state of health estimation methods for lithium-ion batteries[J]. *Automation of Electric Power Systems*, 2024, 48(20): 109-129. DOI: 10.7500/AEPS20231221006.
- [9] 汪宇航, 黄海宏, 王海欣, 等. 基于荷电状态差异的退役电池健康状态快速估计研究[J]. *仪器仪表学报*, 2023, 44(12): 55-68. DOI: 10.19650/j.cnki.cjsi.J2311641.
- WANG Y H, HUANG H H, WANG H X, et al. Research on fast estimation of the state of health of retired batteries based on the state of charge differences[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(12): 55-68. DOI: 10.19650/j.cnki.cjsi.J2311641.
- [10] 霍德鑫, 范国栋, 张希, 等. 基于电化学模型的全固态电池健康状态估计[J]. *电源技术*, 2025, 49(5): 1006-1012. DOI: 10.3969/j.issn.1002-087X.2025.05.016.
- HUO D X, FAN G D, ZHANG X, et al. State of health estimation of all-solid-state batteries based on electrochemical model[J]. *Chinese Journal of Power Sources*, 2025, 49(5): 1006-1012. DOI: 10.3969/j.issn.1002-087X.2025.05.016.
- [11] 金帅, 董静. 基于数据驱动的锂离子电池健康状态估计研究进展综述[J]. *仪器仪表学报*, 2024, 45(3): 45-59.
- JIN S, DONG J. A review of research progress on data-driven state of health estimation for lithium-ion batteries[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(3): 45-59.
- [12] 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. DOI: 10.19595/j.cnki.1000-6753.tces.231085.
- GU J P, JIANG L, ZHANG X S, et al. Estimation and influencing factor analysis of lithium-ion batteries state of health based on features extraction[J]. *Transactions of China Electrotechnical Society*, 2023, 38(19): 5330-5342. DOI: 10.19595/j.cnki.1000-6753.tces.231085.
- [13] 申江卫, 折亦鑫, 舒星, 等. 基于短时随机充电数据和优化卷积神经网络的锂电池健康状态估计[J]. *储能科学与技术*, 2025, 14(4): 1585-1595.
- SHEN J W, SHE Y X, SHU X, et al. State of health estimation for lithium batteries based on short-term random charging data and optimized convolutional neural network[J]. *Energy Storage Science and Technology*, 2025, 14(4): 1585-1595.
- [14] 张瑛, 康永哲, 段彬, 等. 基于数据-模型双驱动的电池组容量在线估计[J]. *机械工程学报*, 2025, 61(2): 210-221.
- ZHANG Y, KANG Y Z, DUAN B, et al. Online estimation of battery pack capacity based on dual driven method of data and model[J]. *Journal of Mechanical Engineering*, 2025, 61(2): 210-221.
- [15] SUN G, LIU Y, LIU X. A method for estimating lithium-ion battery state of health based on physics-informed machine learning[J]. *Journal of Power Sources*, 2025, 627: DOI: 10.1016/j.jpowsour.2024.235767.
- [16] WANG J Y, ZHANG C P, ZHANG L J, et al. A novel aging characteristics-based feature engineering for battery state of health estimation[J]. *Energy*, 2023, 273: 127169. DOI: 10.1016/j.energy.2023.127169.
- [17] 范鑫源. 考虑不一致性的电池组建模方法及应用研究[D]. 北京: 北京交通大学, 2023.
- FAN X Y. Research on modeling method and application of battery pack considering inconsistency[D]. Beijing: Beijing Jiaotong University, 2023.
- [18] 许万里, 洪小波, 王东阳, 等. 基于一致性检验的锂离子电池组健康状态预测[J]. *电源技术*, 2025(4): 772-781.
- XU W L, HONG X B, WANG D Y, et al. Prediction of lithium-ion battery pack SOH based on consistency check[J]. *Chinese Journal of Power Sources*, 2025(4): 772-781.
- [19] DU Y H, SONG Y C, LIU D T. Degradation modeling of serial space lithium-ion battery pack based on online inconsistency representation parameters[J]. *Journal of Power Sources*, 2024, 624: 235608. DOI: 10.1016/j.jpowsour.2024.235608.
- [20] ZHOU Z K, DUAN B, KANG Y Z, et al. Online state of health estimation for series-connected LiFePO₄ battery pack based on differential voltage and inconsistency analysis[J]. *IEEE Transactions on Transportation Electrification*, 2024, 10(1): 989-998. DOI: 10.1109/TTE.2023.3274819.
- [21] MU A X, ZHANG B J, LI C G, et al. Estimating SOC and SOH of energy storage battery pack based on voltage inconsistency using reference-difference model and dual extended Kalman filter[J]. *Journal of Energy Storage*, 2024, 81: 110221. DOI: 10.1016/j.

- est.2023.110221.
- [22] DIAO W P, JIANG J C, ZHANG C P, et al. Energy state of health estimation for battery packs based on the degradation and inconsistency[J]. Energy Procedia, 2017, 142: 3578-3583. DOI: 10.1016/j.egypro.2017.12.248.
- [23] ZHANG X, WANG Y J, LIU C, et al. A novel approach of battery pack state of health estimation using artificial intelligence optimization algorithm[J]. Journal of Power Sources, 2018, 376: 191-199. DOI: 10.1016/j.jpowsour.2017.11.068.
- [24] 王子鹏, 黄凯, 孙恺, 等. 基于源域电池迭代模块和 LSTM 神经网络的锂离子电池寿命预测[J]. 电源学报, 2025, 23(7): 294-303.
- WANG Z P, HUANG K, SUN K, et al. Prediction of remaining useful life of lithium-ion battery based on source-domain battery iterations module and LSTM neural network[J]. Journal of Power Supply, 2025, 23(7): 294-303.
- [25] 赵沁峰, 蔡艳平, 王新军. 锂离子电池全生命周期剩余使用寿命预测[J]. 电源学报, 2024, 22(2): 197-204.
- ZHAO Q F, CAI Y P, WANG X J. Remaining useful life prediction for full life cycle of lithium-ion battery[J]. Journal of Power Supply, 2024, 22(2): 197-204.