新型储能技术在可再生能源系统中的应用专刊

基于弛豫时间分布和物理信息神经网络的锂离子电池健康状态估计

张俊军，何十全
（电子科技大学，四川 成都 611731）

摘 要：精准的健康状态预测对于保障锂离子电池的运行安全至关重要。工程中多通过采集充放电片段的电压、电流、温度等信息，基于数据驱动的AI模型分析其时域特征，实现锂离子电池的健康状态（state of health，SOH）预估。然而传统方法易受复杂运行工况干扰，导致模型泛化失效。本研究提出一种融合弛豫时间分布（distribution of relaxation times，DRT）与物理约束神经网络（physics-informed neural networks，PINN）的SOH估计方法。该方法将频域阻抗数据映射至弛豫时间尺度域，增强不同时间尺度阻抗响应的可分辨性，并提取与电池衰减过程相关的健康特征。进一步结合物理信息神经网络，将电池衰减规律作为物理约束融入损失函数，提升模型在小样本与变工况下的稳定性。结果对比显示，相较于多层感知器、卷积神经网络、Transformer及极限梯度提升（extreme gradient boosting，XGBoost）等模型，本方法在测试集上取得了更低的均方根误差（root mean square error，RMSE）和平均绝对百分比误差（mean absolute percentage error，MAPE）。这表明将弛豫时间分布特征与物理约束神经网络相结合，可有效提升锂电池SOH估计性能。

关键词：健康状态；弛豫时间分布；物理信息神经网络
doi：10.19799/j.cnki.2095-4239.2026.0373
中图分类号：TM 911 文献标志码：A 文章编号：2095-4239（2026）11-4515-17

Estimation of state of health for lithium-ion batteries based on distribution of relaxation times and physics-informed neural networks

ZHANG Junjun, HE Shiquan
(University of Electronic Science and Technology of China, Chengdu 611731, Sichuan, China)

Abstract: Accurate state-of-health (SOH) prediction is crucial for ensuring the safe operation of lithium-ion batteries. In engineering, it is common to collect voltage, current, and temperature data during charge and discharge cycles, and then use data-driven artificial intelligence (AI) models to analyze their time-domain features to estimate the battery's SOH. However, traditional AI methods are sensitive to the complex operating conditions, which leads to poor model generalization. This paper proposes an SOH estimation method that combines relaxation time distribution with physically-informed neural networks. The method maps frequency-domain impedance data to the relaxation time scale to enhance the distinguishability of impedance responses at different time scales and extract health features

收稿日期：2026-05-06；修改稿日期：2026-06-29。
第一作者：张俊军（2003—），男，硕士研究生，研究方向为深度学习、BMS、人工智能应用开发，E-mail：202522020115@stu.uestc.edu.cn；**通信作者：**何十全，副教授，研究方向为计算电磁学、电磁兼容、毫米波雷达及机器视觉（图像识别、人工智能）融合技术，E-mail：shiquanhe@uestc.edu.cn。
引用本文：张俊军, 何十全. 基于弛豫时间分布和物理信息神经网络的锂离子电池健康状态估计[J]. 储能科学与技术, 2026, 15(11): 4515-4531.
Citation：ZHANG Junjun, HE Shiquan. Estimation of state of health for lithium-ion batteries based on distribution of relaxation times and physics-informed neural networks[J]. Energy Storage Science and Technology, 2026, 15(11): 4515-4531.

related to battery degradation. Moreover, by integrating a physics-informed neural network, battery degradation rules are incorporated as physical constraints into the loss function, improving model stability under small sample sizes and variable conditions. Comparison results show that, compared to MLP, CNN, Transformer, and XGBoost models, our method achieves lower RMSE and MAPE values on the test set. This indicates that combining distribution of relaxation time features with physics-informed neural networks can effectively improve lithium battery SOH estimation.

Keywords: SOH; DRT; PINN

锂离子电池作为电动汽车与储能系统的核心支撑，其在长期循环使用中不可避免地会出现容量衰减与内阻升高，这不仅削弱了系统可靠性，极端情况下还可能引发热失控等严重安全隐患[1-3]。因此，精准评估锂离子电池健康状态并预测其演化规律，对于优化维护策略、保障系统安全运行至关重要[4-5]。

健康状态（state of health，SOH）的估计方法主要分为实验方法、基于模型的方法与基于数据驱动的方法三类。实验方法计算复杂度低，但在线运行需要额外的硬件支持，且抗噪能力较差[6]；基于模型的方法依托电池电化学机理模型或等效电路模型，可从物理层面表征电池内部特性，但其建模过程复杂，模型参数易受温度、老化状态等因素影响，精度高度依赖模型合理性，工程化在线应用存在一定局限[7]；传统数据驱动模型多基于时域电压与电流特征构建，当实际工况与训练设置产生偏差时，模型泛化能力往往严重下降甚至失效[8-9]。相比之下，电化学阻抗谱（electrochemical impedance spectroscopy，EIS）技术能全面映射电池全生命周期的电化学演变机理，随着多款在线EIS测量芯片（如NXP、TI等）的商用化，基于EIS的SOH在线估计已成为极具潜力的技术途径[10]。

然而，EIS频域内各类电化学反应特征高度重叠，传统等效电路模型（equivalent circuit model，ECM）对先验经验具有强依赖性，难以自适应电池复杂的退化过程，导致SOH估计精度受限。DRT技术无须预设电路拓扑结构，可有效分离不同时间常数对应的极化过程，在SOH估计中展现出优异的可解释性与环境适应性[11-13]，但DRT求解本质上属于病态逆问题，易出现假峰伪影、计算不收敛等难题，限制了其工程化应用[14-15]。针对这一瓶颈，文献[16]引入高频电感与低频恒相位元件（constant phase element，CPE）修正非理想测量因素，结合分频域EIS分析策略消除假峰干扰、简化计算流程，借助DRTtools工具完成EIS数据解卷积，提取与电池退化机制高度相关的健康特征，并结合高斯过程回归（Gaussian process regression，GPR）模型在公开数据集上实现了SOH高精度估计。

尽管GPR等传统纯数据驱动模型具备较高的估计精度与计算效率，但其泛化性能高度依赖特征提取的有效性和稳定性，受实际工况变异性影响，现有方法需针对不同数据集或工作条件设计专用特征提取策略，造成计算资源冗余[17]。物理信息神经网络通过嵌入电池电化学机理约束，突破了传统数据驱动模型对样本量的依赖，可在小样本条件下实现稳定、精准预测[18-19]。文献[20]提出的B2混合集成PINN架构，通过提取电池满充前短时间内的电压-电流曲线特征输入网络，在多数据集的常规、小样本及迁移实验中均表现优异，彰显了物理信息机器学习在电池退化建模与SOH估计领域的应用潜力。

现有锂离子电池SOH估计方法已由单一模型驱动或纯数据驱动逐步向机理信息与智能算法融合方向发展[6, 21]。EIS能够反映电池内部多时间尺度电化学过程；DRT方法可进一步分离阻抗谱中相互重叠的极化响应[22]，提高健康特征的可解释性；而PINN通过在神经网络训练过程中引入电池退化规律约束，可改善纯数据驱动模型在小样本和变工况下稳定性不足的问题。然而，现有EIS/DRT+GPR、XGBoost等方法多依赖统计映射关系，缺少对SOH衰减趋势的显式约束[23]；现有DRT+深度学习方法虽能增强特征表征能力，但模型物理一致性仍不足；现有PINN类方法则多采用时域充放电片段或经验健康因子作为输入，对EIS中蕴含的频

域机理信息利用不充分[24]。因此，将DRT的频域机理特征提取能力与PINN的物理约束建模能力相结合，仍具有进一步研究的价值。

基于此，本研究提出一种融合改进型DRT与PINN的锂离子电池SOH估计方法。与现有DRT+机器学习方法相比，本研究不仅提取具有物理含义的低维DRT健康特征，还将SOH衰减规律嵌入神经网络损失函数，以增强模型对电池退化趋势的约束能力；与传统PINN方法相比，本研究引入EIS-DRT特征作为输入，使模型能够同时利用频域阻抗信息与退化物理先验。该方法在提升SOH估计精度的同时，兼顾特征可解释性和模型轻量化，为面向BMS的锂离子电池健康状态在线估计提供了一种可行思路。

1　基于DRT的建模参数计算和健康特征提取

1.1　锂电池EIS数据集

本研究采用与文献[16]相同的Nature子刊公开电池老化数据集中的EIS数据，对所提出模型的SOH估计性能进行验证。为考察模型在不同温度和不同荷电状态（state of charge，SOC）条件下的泛化能力与稳定性，本研究选取了25℃、35℃和45℃三种温度环境下的电池EIS数据，并进一步考虑SOC为0%和100%的两类典型工况。所选数据覆盖不同温度、不同SOC及不同老化阶段，能够较好地反映电池在多工况条件下的阻抗特征变化。各工况对应的电池数据标号如表1所示。

表1　不同温度和SOC工况下的电池数据标号

Table 1　Battery data labels under different temperatures and SOC conditions

工况条件	数据标号
25℃，0% SOC	25_CI01、25_CI02、25_CI03、25_CI05、25_CI06
25℃，100% SOC	25_CV01、25_CV02、25_CV03、25_CV05、25_CV06
35℃，0% SOC	35_CI01、35_CI02
35℃，100% SOC	35_CV01、35_CV02
45℃，0% SOC	45_CI01、45_CI02
45℃，100% SOC	45_CV01、45_CV02

在模型训练与验证过程中，本研究利用不同老化阶段采集的EIS数据提取健康特征，并以对应SOH作为监督标签，构建SOH估计模型。工程应用中通常将电池可用容量衰减至初始容量的80%作为寿命终点（end of life，EOL）判据。考虑到实际测试过程中容量测量可能受到实验误差、工况波动及数据噪声影响，为降低边界样本误判对模型训练和评价结果的影响，本研究将寿命终点阈值设定为初始容量的75%，并据此筛选用于建模分析的有效老化数据。

1.2　基于DRT的锂离子电池阻抗模型

锂离子电池内部电化学反应可视为多个连续的极化子过程，在电学上等效为电阻与电容并联，每个单元在阻抗谱中呈现一个特征半圆[25]。当不同过程的弛豫时间接近时，对应半圆发生混叠，难以精确区分。弛豫时间分布方法可解析各过程主导的时间常数，提升动力学在时间维度上的解释能力。然而，实际工况下电池退化过程复杂，线路电感、中间相及催化材料等因素均对阻抗谱产生干扰，若处理不当将导致拟合精度下降并诱发伪峰。为此，本研究采用文献[16]所述方法，引入高频电感L和CPE元件修正上述非理想因素，构建改进型锂离子电池阻抗模型，有效提升阻抗谱解析能力。该模型由高频电感L、欧姆电阻R_∞、表征多个极化过程的电阻-电容并联单元及CPE级联构成。改进型DRT阻抗模型的频域表达式，如式(1)所示。

$$Z_{\mathrm{DRT}}(f)=\mathrm{j}2\pi fL+R_\infty+\int_{-\infty}^{+\infty}\frac{\gamma\ln(\tau)}{1+\mathrm{j}2\pi f\tau}\mathrm{d}\left[\ln(\tau)\right]+\frac{1}{Q}(\mathrm{j}2\pi f)^{-\alpha} \tag{1}$$

式中，$\gamma\ln(\tau)=\tau g(\tau)$，$\gamma\ln(\tau)$为时间常数（$-\infty$，$+\infty$）的弛豫时间分布函数，也写作$\gamma(\tau)$；$R_\infty$是欧姆电阻；$\tau$是RC元件的弛豫时间；j是单位虚数；$f$是频率；$L$为电感；$Q$和$\alpha$为CPE元件系数。

但鉴于嵌入式系统对算法轻量化的严格限制，以及实现“特征提取-SOH联合估计”一体化部署的实际需求，本研究未沿用文献[16]中依赖第三方工具箱（如DRTtools）的常规方案。为提升算法的自主性与可移植性，本研究基于Python语言，自主构建了以最小二乘法为核心的DRT数值解算模型。

根据式(1)，通过从每个频率的测量阻抗中减去电感、欧姆电阻和CPE元件3个阻抗值，得到极化过程的阻抗，剩余的阻抗用于拟合$\gamma\ln(\tau)$。将式(1)中已求得的阻抗L、R_∞和CPE减去并离散化得到式(2)。

$$\begin{cases} Z_{\mathrm{re}}(f) = \sum_{i=1}^{n} \dfrac{\gamma\ln(\tau_i)\Delta\ln(\tau)}{1+(2\pi f)^2\tau_i^2} \\ Z_{\mathrm{im}}(f) = \sum_{i=1}^{n} -\dfrac{2\pi f\tau_i\gamma\ln(\tau_i)\Delta\ln(\tau)}{1+(2\pi f)^2\tau_i^2} \end{cases} \tag{2}$$

上述方程的解算方法在诸多文献中已有详细叙述，如文献[26]，本研究不再赘述。本研究自主构建了以最小二乘法为核心的DRT数值解算模型，核心机制如下。

由于电化学阻抗谱（EIS）的弛豫时间分布（DRT）解析本质上是一个积分方程的求解过程，本研究首先对连续的弛豫时间常数τ进行对数等距离散化。为覆盖测试频率范围并避免边界截断效应，离散化时间常数的上下界由最低测试频率$f_{\min}$和最高测试频率$f_{\max}$确定，即

$$\begin{cases} \tau_{\min} = \dfrac{1}{2\pi f_{\max}} \\ \tau_{\max} = \dfrac{1}{2\pi f_{\min}} \end{cases} \tag{3}$$

本算法中将该区间在对数尺度上均匀划分为N=130个节点，以兼顾计算效率与弛豫峰的分辨率。离散化后，原积分方程转化为矩阵形式：

$$\boldsymbol{Ax} = \boldsymbol{b} \tag{4}$$

式中，$\boldsymbol{A}$为基于RC并联电路阻抗特征构建的核矩阵（包含实部与虚部）；$\boldsymbol{b}$为剥离欧姆内阻、高频电感及低频扩散效应后的纯极化阻抗向量；$\boldsymbol{x}$为待求的DRT离散向量。

DRT解算是一个典型的不适定反问题，微小的测量噪声极易导致极化求逆过程发散。为提升解的鲁棒性，本研究采用吉洪诺夫正则化（Tikhonov regularization）策略，构建了如下带非负约束的最优化目标函数：

$$\min_{\gamma\geqslant 0}\left(\|\boldsymbol{Ax}-\boldsymbol{b}\|_2^2+\delta\|\boldsymbol{Mx}\|_2^2\right) \tag{5}$$

式中，第一项为拟合残差项，第二项为正则化惩罚项；δ为正则化参数（本研究中设定δ=0.001），用于在拟合精度与解的平滑度之间取得平衡；$\boldsymbol{M}$采用二阶差分矩阵，用于近似连续函数的二阶导数。

通过上述频域分离方法，本研究成功求解了所构建阻抗模型中的全部参数，并进一步获得了不同工况下的DRT计算结果。图1展示了不同温度和SOC条件下的EIS拟合结果及对应的DRT谱。其中，黑色散点表示实测EIS数据，红色曲线表示模型拟合结果，蓝色曲线表示求解得到的DRT分布。

由图1(a)可知，在25℃、0% SOC工况下，所构建阻抗模型能够较好地拟合实测阻抗谱，其阻抗实部RMSE为0.0062，阻抗虚部RMSE为0.0112，拟合曲线与实测数据具有较高的一致性，说明该模型能够准确表征电池在该工况下的阻抗响应特征。同时，图1(b)~(f)进一步给出了不同SOC和不同温度条件下的EIS拟合与DRT求解结果。可以看出，在25℃、35℃和45℃以及0% SOC、100% SOC等多种工况下，模型拟合曲线均能够较好地跟随实测阻抗谱变化趋势，表现出较高的阻抗谱拟合精度。

此外，各工况下的DRT谱均呈现出较为清晰的特征峰分布，能够有效分离不同时间尺度下的电化学过程。DRT结果更直观地揭示电池内部极化过程的变化特征，并在一定程度上抑制非真实弛豫过程引起的伪峰干扰。上述结果表明，本研究采用的频域分离与DRT求解方法不仅具有较高的EIS拟合精度，而且在不同温度和SOC工况下均保持较好的稳定性，说明该方法具有一定的多工况适应能力和抗干扰能力。

为进一步验证自主DRT解算方法的可靠性，本研究将其与主流工具DRTtools的拟合结果进行定量对比，将电池25_CI01的第一次充放电循环测得的EIS数据分别用本研究的方法和DRTtools进行DRT计算，具体数据结果如表2所示。DRTtools的阻抗实部与虚部拟合RMSE分别为0.019和0.0034，与本方法的拟合误差处于同一量级，表明两者整体精度相当。在计算效率方面，本方法单次DRT计算仅耗时25.3 ms，内存占用低至13 KB；相比之下，DRTtools耗时达197 ms，内存占用为87 KB。由此可见，本研究设计的解算方法更易于在嵌入式系统中部署。综上所述，本研究自主构建的DRT数值解算方法结果准确可信，能够为后续的SOH估计提供高质量的特征输入。

为进一步分析锂离子电池在全生命周期内阻抗特征的演化规律，本研究对不同电池、不同温度及不同SOC工况下的EIS数据进行DRT求解，结果如图2所示。图中颜色由蓝色逐渐过渡至红色，表示电池由新鲜状态逐步老化至衰退状态。可以看

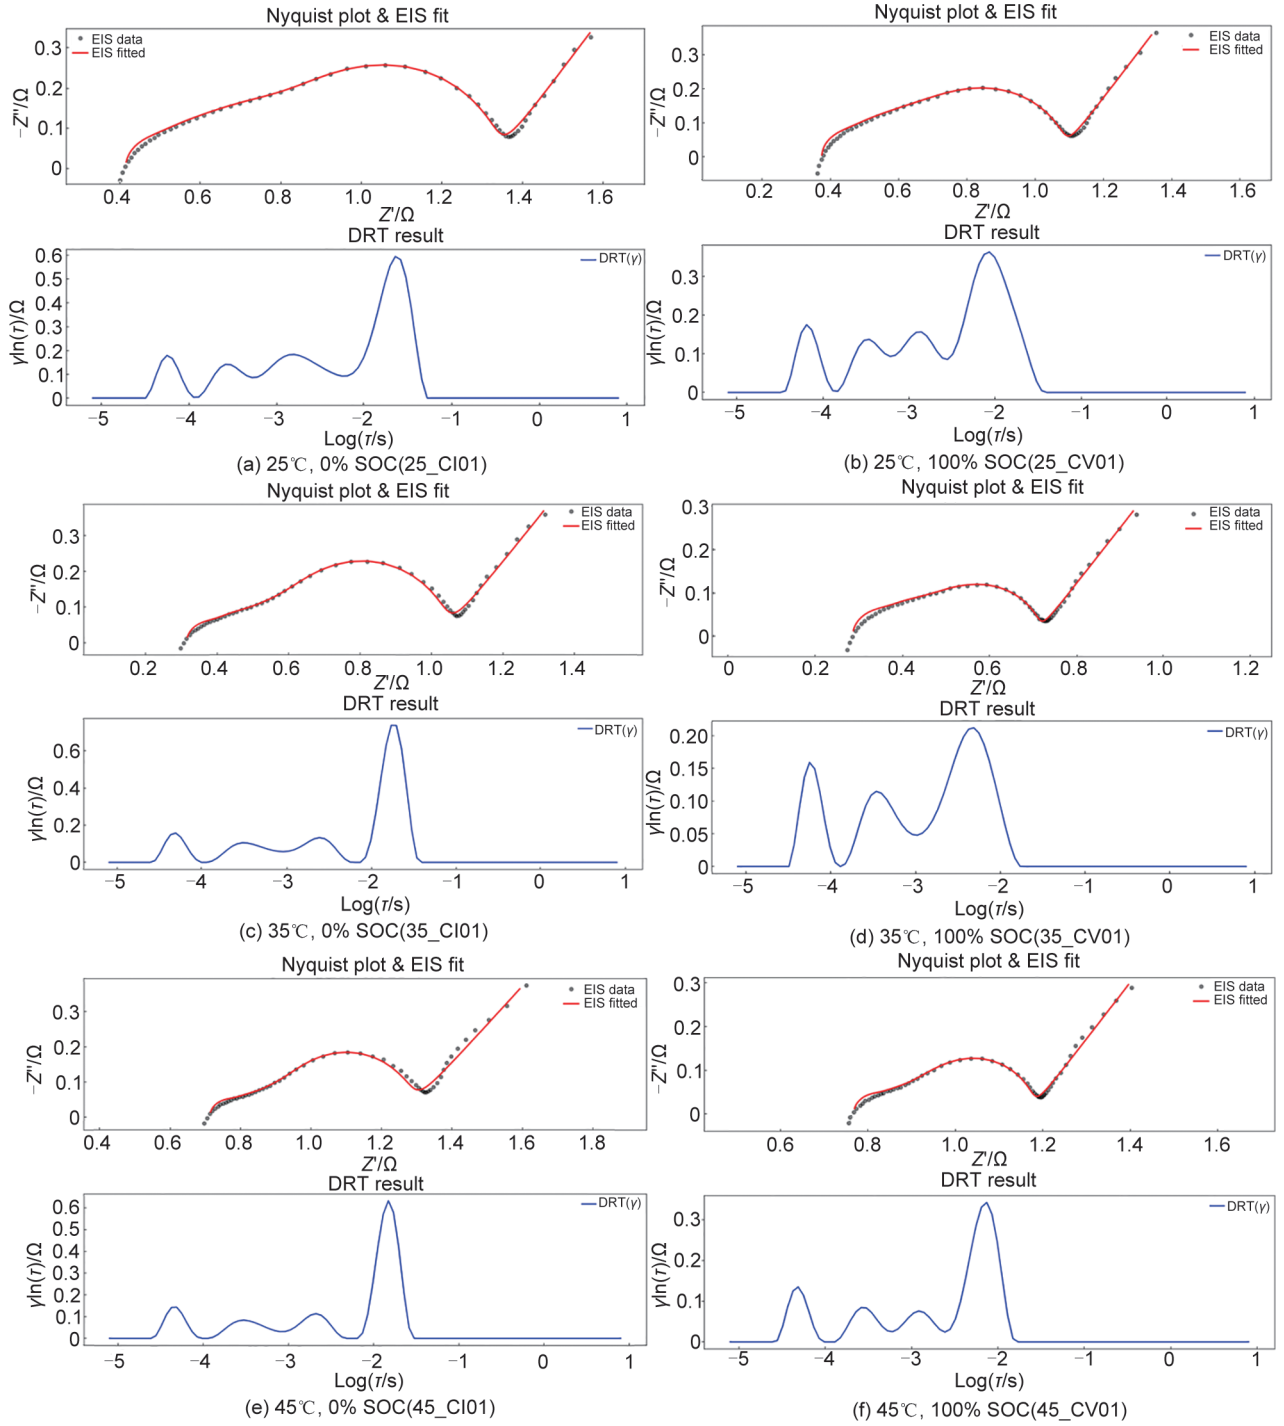


图1　不同工况下锂电池的DRT阻抗模型EIS拟合结果图：(a) 25℃，0% SOC；(b) 25℃，100% SOC；(c) 35℃，0% SOC；(d) 35℃，100% SOC；(e) 45℃，0% SOC；(f) 45℃，100% SOC

Fig. 1　DRT impedance model EIS fitting results of lithium batteries under different working conditions: (a) 25℃, 0% SOC; (b) 25℃, 100% SOC; (c) 35℃, 0% SOC; (d) 35℃, 100% SOC; (e) 45℃, 0% SOC; (f) 45℃, 100% SOC

出，各工况下的DRT谱均呈现出多个较为稳定的特征峰。以图2(a)为例，DRT曲线中可识别出4个主要特征峰，按照弛豫时间由短到长依次标记为P1、P2、P3和P4。不同特征峰对应不同时间尺度下的阻抗响应过程，但其具体电化学归属仍需结合进一步的原位表征或机理模型验证，因此本研究仅

表2 自主DRT解算模型与DRTtools的性能对比

Table 2 Performance comparison between the autonomous DRT solving model and DRTtools

对比性能	本方法	DRTtools
阻抗实部拟合RMSE	0.0062	0.019
阻抗虚部拟合RMSE	0.0112	0.0034
计算耗时/ms	25.3	197.0
代码占用内存/KB	13	87

将其作为表征电池老化状态的特征响应峰进行分析。

从全生命周期演化趋势来看，随着电池老化程度加深，各特征峰的幅值、峰面积以及峰形均发生明显变化。其中，P4峰在多数工况下表现出较显著的增强趋势，说明长弛豫时间区域的阻抗响应随老化过程逐渐增强；而P1、P2和P3峰在不同电池和工况下呈现不同程度的变化，反映出中高频区域阻抗响应也会随电池老化而发生演化。与此同时，各峰的中心位置整体保持相对稳定，说明在老化过程中主要特征响应所在的时间尺度未发生明显迁

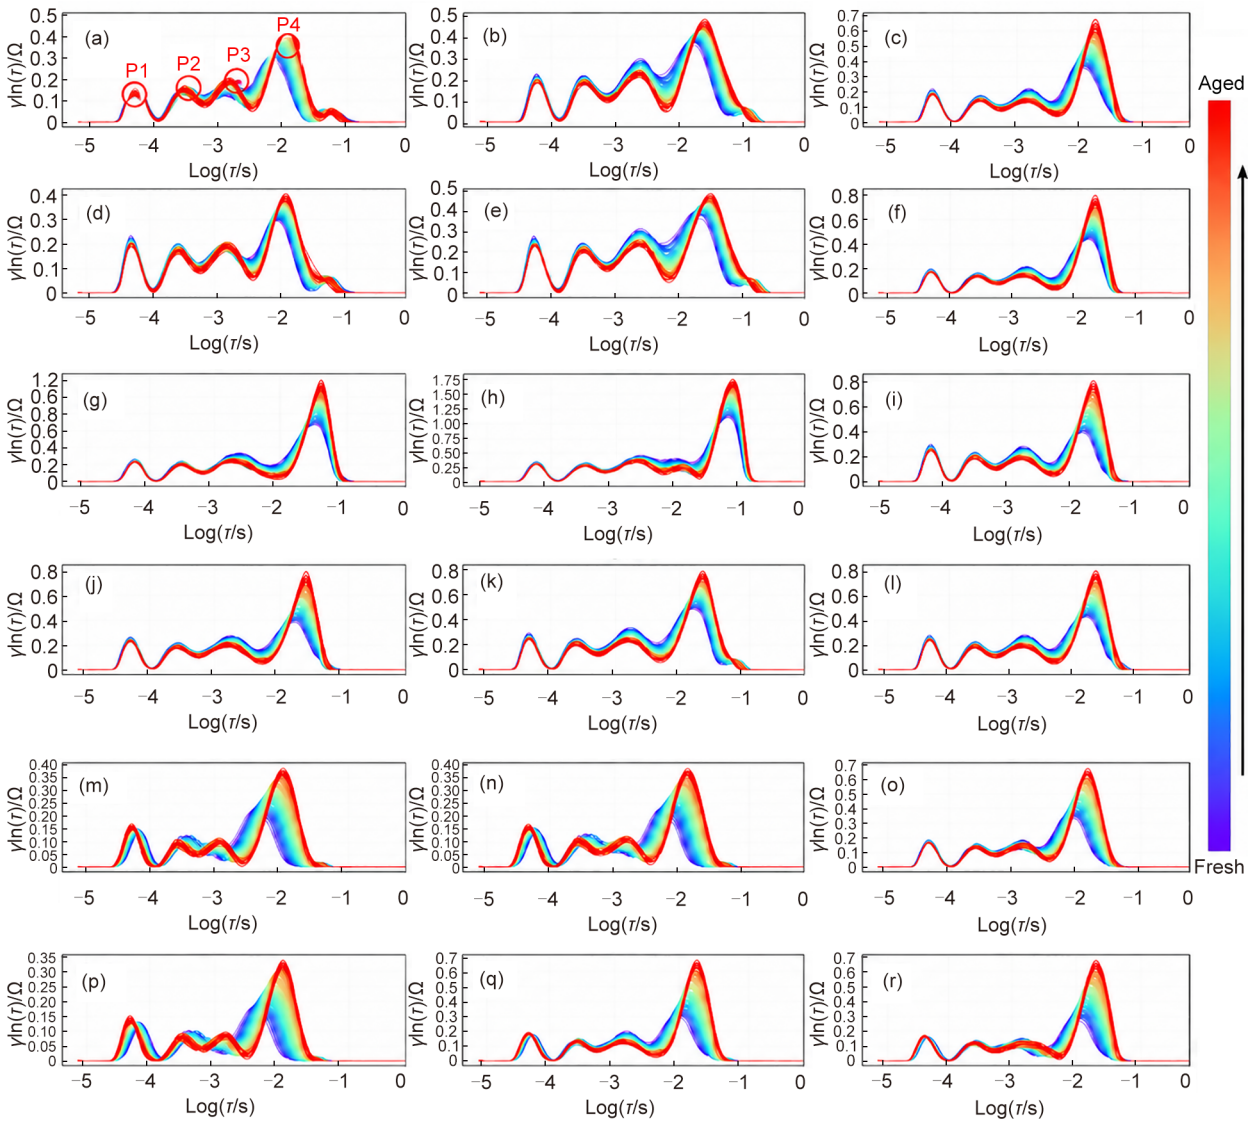


图2 不同工况下电池衰老过程中弛豫时间的拟合分布函数：(a) 25_CV01；(b) 25_CV02；(c) 25_CV03；(d) 25_CV05；(e) 25_CV06；(f) 25_CI01；(g) 25_CI02；(h) 25_CI03；(i) 25_CI05；(j) 25_CI06；(k) 35_CI01；(l) 35_CI02；(m) 35_CV01；(n) 35_CV02；(o) 45_CI01；(p) 45_CI02；(q) 45_CV01；(r) 45_CV02

Fig. 2 Fitted distribution functions of relaxation time during battery aging under different operating conditions: (a) 25_CV01; (b) 25_CV02; (c) 25_CV03; (d) 25_CV05; (e) 25_CV06; (f) 25_CI01; (g) 25_CI02; (h) 25_CI03; (i) 25_CI05; (j) 25_CI06; (k) 35_CI01; (l) 35_CI02; (m) 35_CV01; (n) 35_CV02; (o) 45_CI01; (p) 45_CI02; (q) 45_CV01; (r) 45_CV02

移，而峰强和峰面积的变化更加适合作为反映电池健康状态衰退的量化指标。

进一步比较图2可以发现，不同电池样本、不同SOC状态以及不同温度条件下的DRT谱均能保持较清晰的峰形结构，且随老化推进呈现出相对一致的演化规律。这说明本研究采用的DRT求解方法能够在多工况数据中有效提取稳定的弛豫特征，并具有一定的工况适应性和抗干扰能力。尤其是在0% SOC与100% SOC、25~45℃等不同测试条件下，DRT谱仍能较好地区分不同老化阶段的特征变化，表明该方法能够为后续健康特征提取提供可靠基础。

1.3　健康特征提取和相关性分析

为保障SOH估计精度，本研究从DRT曲线中提取与容量衰减强相关的健康特征。首先基于阻抗模型提取代表性特征，进而通过相关性分析筛选出与SOH高度相关的特征。重点对$\gamma\ln(\tau)$曲线进行数值化处理，提取峰值、谷值、积分等可表征曲线形态与变化趋势的特征。该方法将曲线数据转化为有效数值特征，为后续SOH估计建模提供可靠输入。在本研究中，从所开发的模型中提取了多个具有典型性的特征，并将其分为3组。

组1：阻抗模型的非极化参数，包括欧姆电阻R_∞、高频电感L、CPE常数Q（CPE_Q）和CPE指数α（CPE_alpha）。

组2：阻抗模型中的极化过程参数，包括极化电阻R_{pol}。

组3：弛豫时间分布函数曲线参数$\gamma\ln(\tau)$，提取4个极化峰的峰值高度{Peak_1_Height，Peak_2_Height，Peak_3_Height，Peak_4_Height}，每个峰对应的Log(τ)值{Peak_1_LogTau，Peak_2_LogTau，Peak_3_LogTau，Peak_4_LogTau}，每个峰的积分面积{Peak_1_Core_Area，Peak_2_Core_Area，Peak_3_Core_Area，Peak_4_Core_Area}，前3个峰的高度与最大峰P4高度的相对比例{Peak_1_Rel_Height，Peak_2_Rel_Height，Peak_3_Rel_Height}，前3个峰的积分面积与最大峰P4积分面积的相对比率{Peak_1_Rel_Area，Peak_2_Rel_Area，Peak_3_Rel_Area}。

在模型参数的特征提取后，得到的特征呈现出非常不同的趋势，直接主观判断特征与SOH之间的相关性容易产生误差。因此，为了进一步量化相关性，使用Pearson相关系数来测量特征与SOH之间的相关性[16]，给出提取特征的测试结果如图3所示。

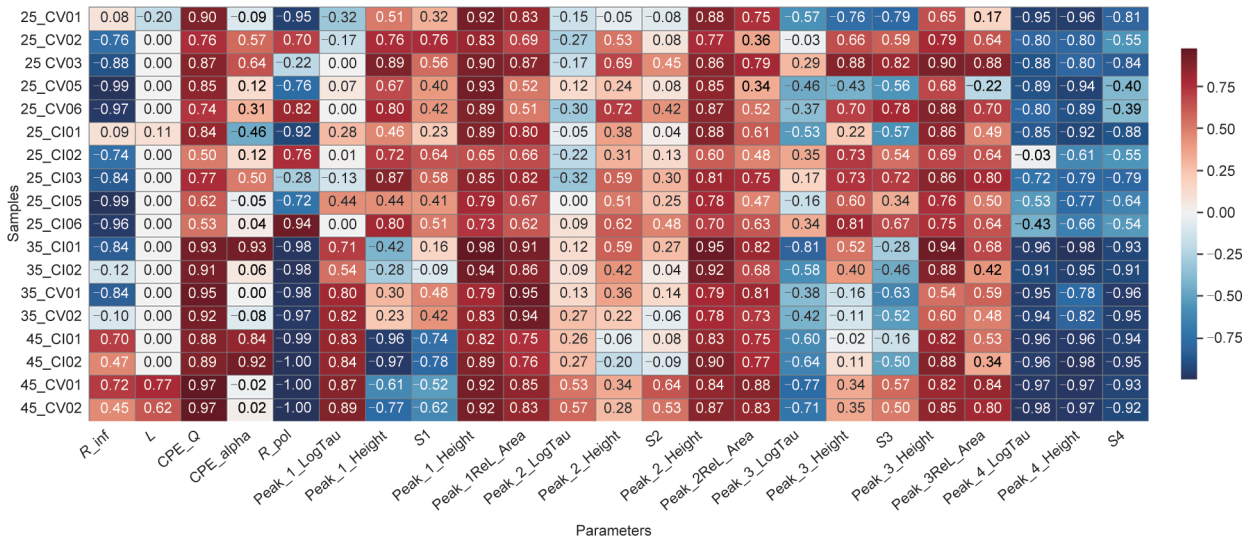


图3　提取特征与电池SOH的Pearson相关系数

Fig. 3　Pearson correlation coefficient between extracted features and five batteries' SOH

为了避免低相关性特征的影响，从图中提取出与电池SOH的相关系数绝对值均大于0.5的高相关性特征，用于后续SOH预测，包括CPE常数Q、P1峰与P4峰的峰值高度相对值（Peak_1_Rel_Height）、P1峰与P4峰的积分面积相对值（Peak_1_Rel_Area）、P2峰与P4峰的峰值高度相对值（Peak_2_Rel_Height）、P3峰与P4峰的峰值高度相对值（Peak_3_Rel_Height）、P4峰的峰值高度（Peak_4_Height）。

图4展示了电池的健康状态与所提取电化学特征的相关性散点图。结果表明，各特征与SOH

均呈现显著线性相关，且跨电池具有高度一致性。其中，CPE 常数 Q 和 P1 峰、P2 峰、P3 峰的归一化高度、面积等特征与 SOH 正相关，其值随老化衰减；而 P4 峰的高度、对数时间常数及核心面积等特征与 SOH 负相关，其值随老化增大。特别是 Peak_4_Height 与 CPE_Q 等特征相关性极强，且同一特征在不同电池间的相关系数差异较小，验证了所提特征的敏感性与普适性。上述分析为后续基于电化学特征的 SOH 估计奠定了可靠基础。

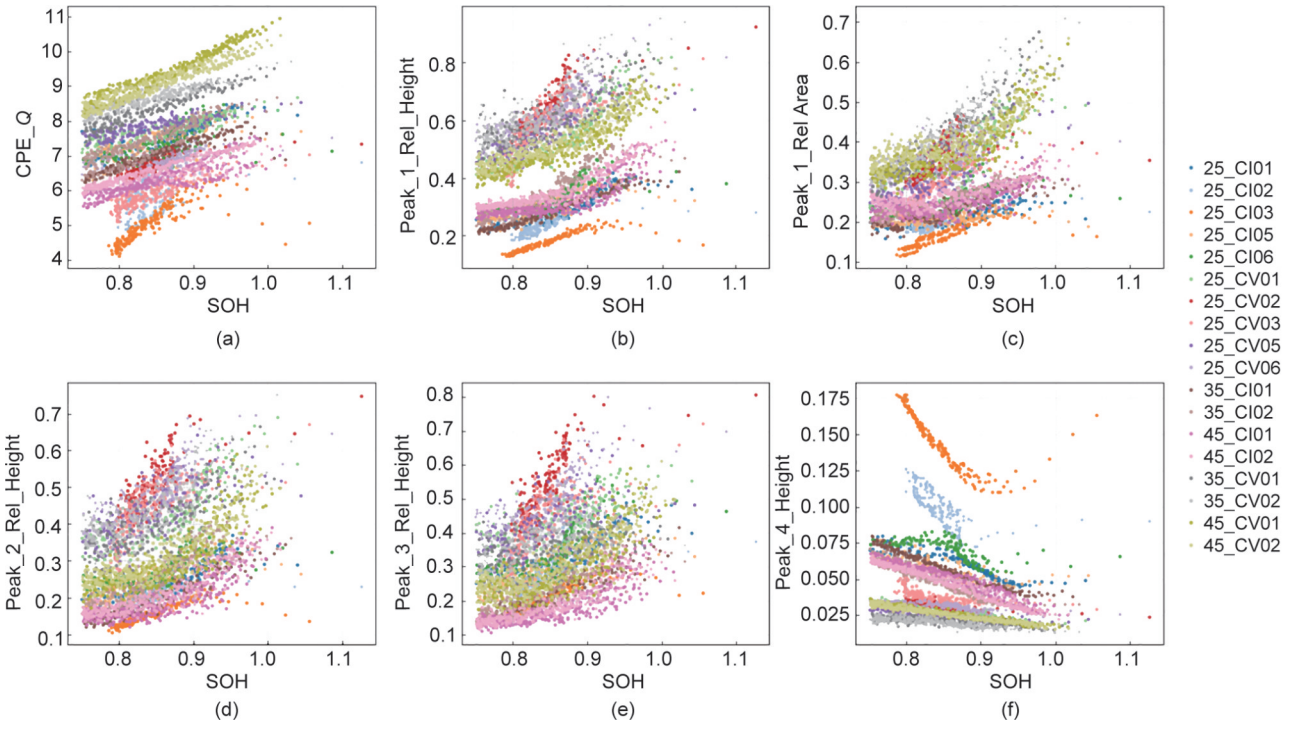


图 4 电池 SOH 与所提取电化学特征的相关性散点图

Fig. 4 Scatter plot of the correlation between the SOH of five batteries and the extracted electrochemical characteristics

尽管 Pearson 相关系数能够衡量单一健康特征与 SOH 之间的线性相关程度，但其无法反映特征之间的内在相关性。为避免高相关特征同时输入模型可能带来的特征冗余和过拟合风险，本研究进一步采用方差膨胀因子（variance inflation factor，VIF）对初筛得到的 6 个高相关性 DRT 特征进行多重共线性检验，结果如图 5 所示。

由图 5 可知，不同温度、SOC 状态及电池数据组中的 VIF 分布存在一定差异，部分 DRT 峰值特征在若干数据组中表现出较高的 VIF 值，说明这些特征之间存在一定程度的线性相关性。这可能与电池老化过程中多个阻抗响应区域随容量衰退同步变化有关，但并不意味着相关特征完全冗余。

考虑到 DRT 峰特征与具体电化学过程之间的对应关系受测试温度、SOC 状态及 DRT 求解参数等因素影响，本研究不对各峰值特征作绝对机理归属，而主要关注其与 SOH 的统计相关性及模型预测贡献。虽然部分特征存在较高 VIF 值，但这 6 个特征均与 SOH 表现出较强关联，且能够从不同弛豫时间区域描述阻抗谱随老化过程的变化。因此，本研究综合 Pearson 相关性、VIF 共线性检验结果、特征维度规模及模型训练需求，最终保留 CPE_Q、Peak_1_Rel_Height、Peak_1_Rel_Area、Peak_2_Rel_Height、Peak_3_Rel_Height 和 Peak_4_Height 作为 SOH 预测模型的输入变量。

该特征组合在保持输入维度较低的同时，保留了阻抗谱中与电池健康状态变化相关的多区域响应信息。后续模型训练中，通过特征归一化及 PINN 物理约束项进一步降低特征冗余对模型稳定性的影响，为 SOH 预测提供可靠的数据基础。

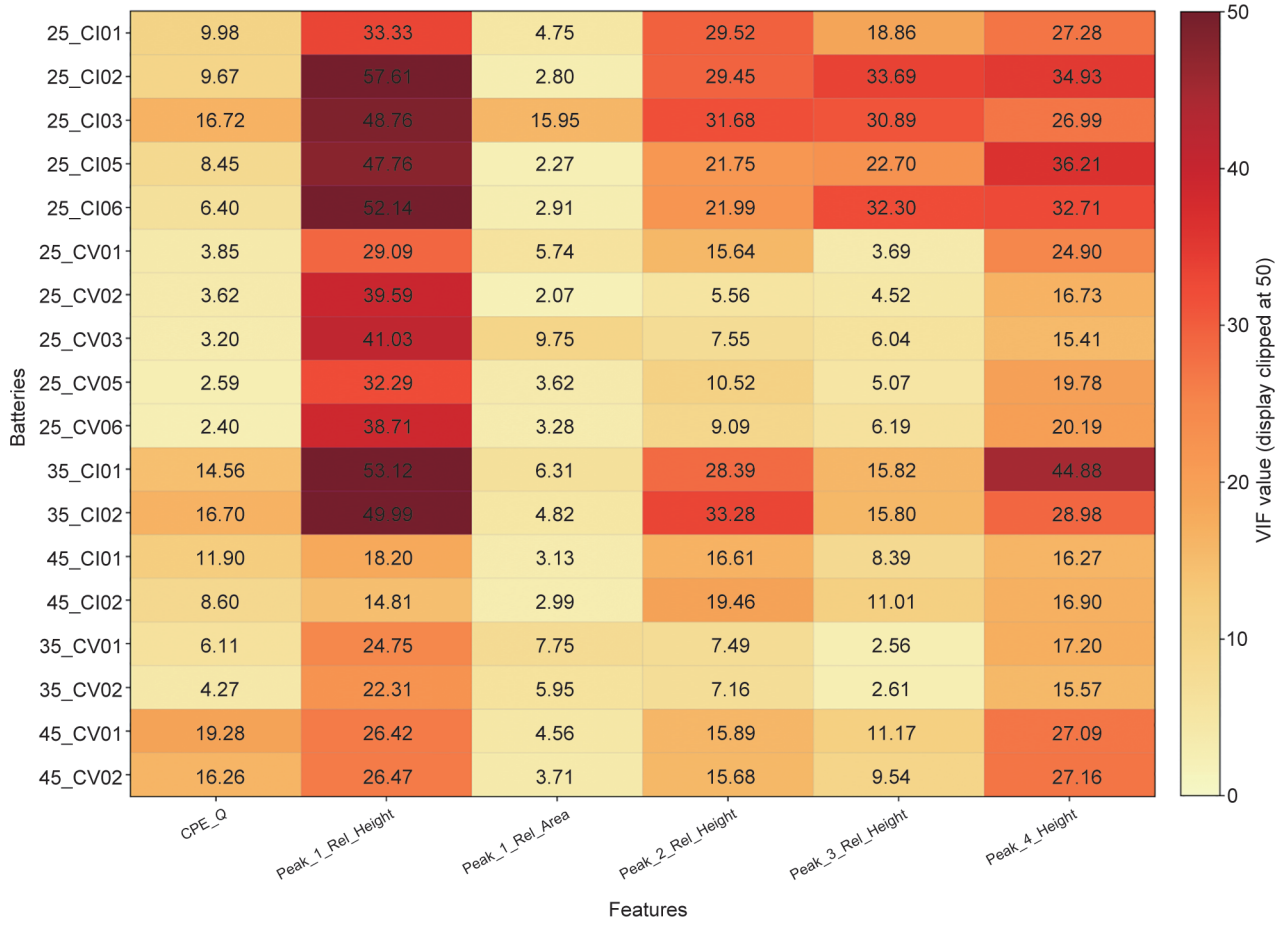


图 5　电池数据集特征的 VIF 计算热力图

Fig. 5　VIF Calculation heatmap of features in battery datasets

2　基于物理信息神经网络(PINN)的 SOH 估计模型

2.1　锂电池退化动力学建模

传统经验模型（如线性、指数或幂律衰减）通常将时间或循环次数视为退化的唯一自变量，掩盖了电池老化的多因素耦合本质，忽略了充放电倍率、温度、放电深度、荷电状态（SOC）及固态电解质界面膜（solid electrolyte interphase，SEI）动态演化等关键因素的影响。已有研究证实，将日历老化与循环老化解耦，并纳入 SOC、放电深度（depth of discharge，DOD）及温度等变量，是准确描述退化过程的必要条件[27]。据此，本研究将电池退化轨迹定义为受多因素控制的多元函数：

$$u = f(\boldsymbol{x}, t) \tag{6}$$

式中，t 为时间；$\boldsymbol{x}$ 为从 EIS 数据中提取的电化学特征多因素的向量；u 对应电池 SOH。

为刻画退化动力学，SOH 的衰减率可由参数化的偏微分方程（partial differential equations，PDE）表示：

$$\frac{\partial u}{\partial t} = g(t, \boldsymbol{x}, u; \theta) \tag{7}$$

式中，$g(\cdot)$ 为 t、$\boldsymbol{x}$ 和 u 的非线性函数；θ 为模型参数。

2.2　PINN 网络构建

在完成基于 DRT 的阻抗建模与高相关性健康特征筛选的基础上，本节采用 PINN 实现稳定、精确的 SOH 估计。该方法通过将物理定律作为约束嵌入网络训练，克服了纯数据驱动方法依赖特定数据分布的局限；同时，具有清晰物理内涵的 DRT 特征有效解耦了 SEI 膜生长、电荷转移等老化机制[28]。二者的深度融合使模型能够依据内在物理规律构建特征与 SOH 的映射关系，在所选公开 EIS 数据集的多温度、多 SOC 工况下表现出较好的估计稳定性，具备进一步向在线 SOH 估计扩展的潜力。

本研究从经验退化状态空间方程的角度，对影响电池退化的属性进行了建模，并利用神经网络来逼近已建立的退化模型，有效地实现了控制方程与神经网络的结合。所构建的PINN由2部分组成：将特征映射到SOH的解函数$F(\cdot)$和模拟电池退化动态行为的非线性函数$G(\cdot)$。详细的PINN构建过程与文献[20]相同，本研究不再赘述，具体请参考文献[20]中方法部分。

解函数$F(\cdot)$采用深度多层感知机结构，包含4个隐藏层，节点数依次递减设为256、128、64、32，以实现特征的高维非线性映射与逐层降维提取；物理网络则包含3个隐藏层，节点数设置为128、64、32。代理网络隐藏层选用Swish激活函数，相较于传统的ReLU，其平滑且非单调的特性在深度回归任务中表现出更优的梯度流传递效率；输出层采用Sigmoid激活函数，将SOH预测值严格约束在(0, 1)的物理有效区间内。物理网络则采用tanh激活函数，以保证网络具有高阶连续可导性，从而满足偏导数计算的平滑性要求。模型采用Adam优化器配合余弦退火学习率衰减策略。初始学习率设定为0.001，随着训练步数逐步衰减至初始值的1%。此策略在训练初期能够快速越过局部最优解，在末期则能保障模型在全局最优点附近的精细收敛。此外，模型引入了L_2正则化与随机失活（dropout）机制，以在极致拟合与防止过拟合之间取得平衡。物理约束（PDE损失）及其对应的退化机理在代码中构建的物理约束主要包含2部分，深刻反映了锂离子电池的内部退化动力学。

退化速率动力学方程：代码通过自微分机制提取SOH对循环次数（cycle）的偏导数$\frac{\partial \mathrm{SOH}}{\partial t}$。物理发现网络尝试学习一个潜在的非线性退化函数$G(\mathrm{SOH}, x)$，使得$\frac{\partial \mathrm{SOH}}{\partial t}=G(\mathrm{SOH}, x)$。这一约束等效于在数据驱动中注入了电池容量衰减的经验动力学模型，反映了由固体电解质界面膜持续增厚、活性物质损失等电化学副反应所主导的非线性退化速率演变规律。

单调递减约束：通过引入ReLU惩罚项[tf.nn.relu(grad_t)]，模型对任何出现容量回升（即$\frac{\partial \mathrm{SOH}}{\partial t}>0$）的预测施加严格的损失惩罚。这直接对应了电池老化的热力学不可逆性原则，即在宏观循环尺度上，电池的最大可用容量应呈现严格的单调衰减趋势。

最终构建的PINN模型结构见图6右半部分。得到的损失函数如下：

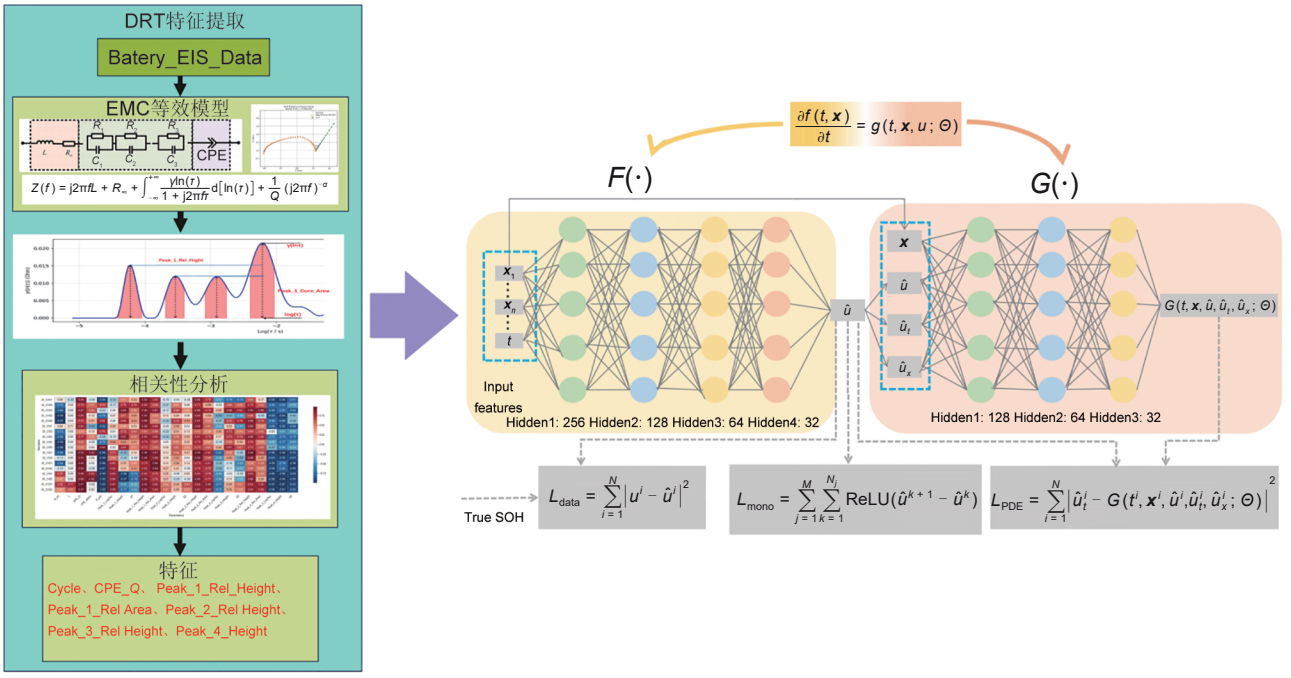


图6 锂电池SOH估计流程图

Fig. 6 Lithium battery SOH estimation flowchart

$$L_{\mathrm{PDE}}=\sum_{i=1}^{N}\left|\frac{\partial F(t,\boldsymbol{x};\Phi)}{\partial t}-G(t,\boldsymbol{x},u,u_t,u_x;\Theta)\right|^2 \tag{8}$$

$$L_{\mathrm{data}}=\sum_{i=1}^{N}\left|u^i-\hat{u}^i\right|^2 \tag{9}$$

$$L_{\mathrm{mono}}=\sum_{j=1}^{M}\sum_{k=1}^{N_j}\mathrm{ReLU}(\hat{u}^{k+1}-\hat{u}^k) \tag{10}$$

$$L=L_{\mathrm{data}}+\lambda L_{\mathrm{PDE}}+\beta L_{\mathrm{mono}} \tag{11}$$

式中，$\frac{\partial F(t,\boldsymbol{x};\Phi)}{\partial t}$表示解神经网络的$F(\cdot)$对$t$的偏导数；$G(\cdot)$表示由神经网络建模的电池退化动态方程；$\Theta$和$\Phi$为模型参数；$\hat{u}^i$表示估计的SOH；$M$代表电池数量；$N$表示电池$j$的循环次数；$t$为时间；$L_{\mathrm{PDE}}$、$L_{\mathrm{data}}$、$L_{\mathrm{mono}}$分别表示物理损失、数据损失和单调性损失；$\lambda$和$\beta$是衡量各项损失的超参数，这两个系数决定了模型在“信任观测数据”与“遵守物理法则”之间的平衡取舍。

为了克服PINN训练中常见的“梯度病态”，即初期物理损失的复杂梯度干扰数据拟合过程，本研究采用一种动态权重分配策略。在训练的前20%个轮次（epochs），赋予极小的物理权重（λ=0.01、β=0.1），迫使模型优先拟合训练数据，建立准确的初始映射空间；在20%之后，大幅提升物理约束权重（λ=1.0、β=2.0），利用物理先验知识对预测曲线进行平滑修正与趋势纠偏，从而显著提升模型在未见数据上的泛化能力。

3　结果验证

3.1　训练和参数优化

为了最小化特征幅值变化对模型性能的影响并提高训练过程的稳定性，本工作应用了最小−最大归一化，将所有特征缩放到[−1, 1]的范围内。这一步骤确保每个特征都能按比例对模型作出贡献。最小−最大归一化公式可以描述如下：

$$x'=\frac{2(x-x_{\min})}{x_{\max}-x_{\min}}-1 \tag{12}$$

式中，$x_{\min}$是数据样本的最小值；$x_{\max}$是数据样本的最大值；x是原始数据；x'是归一化数据值。

关于SOH估计，代码摒弃了仅用单块电池按时序截断的传统验证方式，将来自不同运行工况的文件合并后进行全局随机打乱，并按60%∶20%∶20%划分训练集、验证集与测试集。这种策略确保了测试集中包含多种工况下的离散衰减片段。总损失函数中还包含PDE损失系数λ和单调性损失系数β，也将对模型性能产生显著影响。在本研究中，采用随机搜索的方法来找到这些参数的最佳组合。同时，也考虑了计算负担，所有估计训练和测试均在个人计算机上进行，处理器为Intel-i7 13650，显卡为NVIDIA GeForce RTX 4060，环境为Python 3.11。

3.2　SOH估计

基于训练完成的PINN模型及筛选后的高相关性DRT特征，开展锂电池SOH估计实验，完整SOH估计流程如图6所示，该流程涵盖EIS数据采集、改进DRT建模与参数计算、特征提取与筛选、PINN模型训练及SOH估计5个核心环节，实现了从原始数据到SOH估计结果的端到端处理，确保了估计过程的系统性与严谨性。

为了定量比较不同模型下SOH估计的性能，本研究采用3种准确性指标，包括R平方（R^2）、平均绝对百分比误差（MAPE）、均方根误差（RMSE）。表达式定义如下：

$$R^2=1-\frac{\sum_{i=1}^{N}(\hat{y}_i-y_i)^2}{\sum_{i=1}^{N}(\hat{y}_i-\bar{y})^2} \tag{13}$$

$$\mathrm{MAPE}=\frac{1}{N}\sum_{i=1}^{N}\left|\frac{\hat{y}_i-y_i}{y_i}\right|\times 100\% \tag{14}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(\hat{y}_i-y_i)^2} \tag{15}$$

式中，N是真实值的数量；$\hat{y}_i$和y_i分别是SOH的估计值和真实值；$\bar{y}$是真实值的平均值；R^2反映估计值与真实值的接近程度，越接近1，SOH的估算值越准确。MAPE和RMSE反映估计值与实际值之间的偏差，这两个指标越接近0，状态估计的准确性越高。

3.2.1　DRT特征与EIS特征对比实验

为验证所提基于融合DRT特征的物理信息神经网络的锂离子电池健康状态估计方法的准确性与泛化能力，并进一步解耦评估模型中DRT模块的独立贡献，本研究基于公开数据集中的商用动力锂电池开展了全生命周期循环老化的消融实验，量化评价结果如表3所示。

表3中，“DRT+PINN”为本研究提出的方法，即提取DRT特征输入PINN模型进行SOH预测；“EIS+PINN”为消融对照组，即直接从原始电化学阻抗谱中提取能够表征不同退化阶段的关键物理特征点作为网络输入。对照组提取的特征具体如下[16, 29]。

表 3 DRT+PINN 与 EIS+PINN 方法的 SOH 估计性能对比

Table 3 Comparison of SOH estimation performance between DRT+PINN and EIS+PINN

电池	DRT+PINN			EIS+PINN		
	RMSE/%	MAPE/%	R^2/%	RMSE/%	MAPE/%	R^2/%
25_CI01	**0.712**	**0.570**	**98.59**	1.474	1.490	93.95
25_CI02	**0.544**	**0.383**	**97.82**	1.414	0.651	85.22
25_CI03	**0.287**	**0.270**	**99.57**	0.610	0.458	98.05
25_CI05	**0.646**	**0.617**	**98.70**	1.145	1.131	95.92
25_CI06	**0.792**	**0.479**	**97.79**	2.114	1.563	84.22
25_CV01	1.277	1.105	95.64	**1.132**	**1.104**	**96.56**
25_CV02	**0.860**	**0.753**	**94.56**	2.003	0.935	70.54
25_CV03	**0.815**	**0.341**	**96.56**	1.610	1.569	86.56
25_CV05	1.521	1.392	92.86	**1.243**	**1.196**	**95.23**
25_CV06	1.528	1.258	91.91	**1.220**	**0.996**	**94.84**
35_CI01	**0.487**	**0.430**	**99.45**	0.550	0.528	99.30
35_CI02	0.528	0.477	99.20	**0.514**	**0.470**	**99.24**
35_CV01	**0.573**	**0.530**	**99.21**	0.635	0.549	99.03
35_CV02	**0.674**	**0.615**	**98.70**	0.792	0.692	98.20
45_CI01	**0.313**	**0.264**	**99.78**	0.416	0.342	99.60
45_CI02	**0.339**	**0.323**	**99.76**	0.614	0.585	99.21
45_CV01	0.321	0.297	99.77	**0.252**	**0.207**	**99.86**
45_CV02	**0.368**	**0.320**	**99.72**	0.413	0.390	99.64

（1）欧姆内阻（R_∞）：虚部 Im(Z)穿过横轴（或高频区实部取得最小值）时的实部值，主要表征电解液与集流体的老化状态。

（2）中频圆弧顶点（Mid_Arc）：Nyquist 图中中频区半圆弧上虚部 Im(Z)达到局部最大值时的实部、虚部及其对应的特征频率。该特征近似表征了固体电解质界面（SEI）膜阻抗与电荷转移阻抗（R_{ct}）的耦合极化特性。

（3）低频扩散点（Low_Freq）：EIS 测试极低频点处的实部与虚部值，主要表征锂离子的固相扩散过程。

设置 EIS+PINN 对照组的目的在于验证：相较于直接从原始 EIS 曲线中提取典型物理特征点，基于 DRT 方法提取的多时间尺度健康特征是否能够为 PINN 模型提供更有效的退化表征信息，从而提升 SOH 估计性能。表 3 给出了 DRT+PINN 与 EIS+PINN 方法在不同温度、不同 SOC 及不同电池编号下的 SOH 估计结果。

由表 3 可知，DRT+PINN 方法在多数工况下均表现出更优的 SOH 估计精度。整体来看，DRT+PINN 在 18 组测试数据上的平均 RMSE、MAPE 和 R^2 分别为 0.699%、0.579% 和 97.76%，而 EIS+PINN 对应指标分别为 1.008%、0.825% 和 94.18%。与 EIS+PINN 相比，DRT+PINN 的平均 RMSE 降低约 30.66%，平均 MAPE 降低约 29.82%，平均 R^2 提高约 3.58 个百分点，说明 DRT 特征能够有效增强 PINN 模型对电池健康状态变化的表征能力。

从单个工况结果来看，DRT+PINN 在 25_CI01、25_CI02、25_CI03、25_CI05、25_CI06 等 0% SOC 数据上具有明显优势，其 RMSE 均低于 0.8%，R^2 均高于 97.7%。其中，25_CI03 工况下的估计效果最优，RMSE 和 MAPE 分别为 0.287% 和 0.270%，R^2 达到 99.57%。在 35℃ 和 45℃ 工况下，DRT+PINN 同样保持较高预测精度，多数组别的 R^2 均接近或超过 99%，表明该方法在不同温度条件下具有较好的稳定性。

相比之下，EIS+PINN 对照组在部分工况下误差较大，尤其在 25_CI02、25_CI06 和 25_CV02 等数据上 R^2 分别为 85.22%、84.22% 和 70.54%，表现出较明显的泛化能力不足。其原因可能在于，直接从 Nyquist 图中选取欧姆内阻、中频圆弧顶点和低频扩散点等特征时，容易受到频段重叠、曲线形貌变化和特征点定位误差的影响，导致所提取特征难以充分表征不同老化阶段下的阻抗响应变化。

需要指出的是，在少数工况下，EIS+PINN 的个别指标略优于 DRT+PINN，例如 25_CV01、25_CV05、25_CV06 和 45_CV01 等工况。这说明原始 EIS 特征在部分特定测试条件下仍具有一定有效性。然而，从整体统计结果和多数工况表现来看，DRT+PINN 在误差控制和拟合优度方面仍占据优势。综合而言，DRT 方法能够将原始 EIS 中耦合的阻抗响应转化为具有多时间尺度分辨能力的弛豫特征，使 PINN 模型获得更稳定、更有效的健康状态输入信息，从而提高 SOH 估计的准确性和多工况适应能力。

图 7 展示了“DRT+PINN”方法在不同温度与 SOC 工况下的 SOH 估计可视化结果。图中黑色实线表示真实 SOH，红色虚线表示 PINN 模型预测 SOH，浅红色填充区域表示以测试集 RMSE 为宽度构建的参考误差带。整体来看，各子图中预测曲线与真实 SOH 曲线具有较高的一致性，能够较好地跟踪电池在全生命周期内的非线性衰减趋势，表明所提方法对不同老化路径下的 SOH 变化具有较强的表征能力。

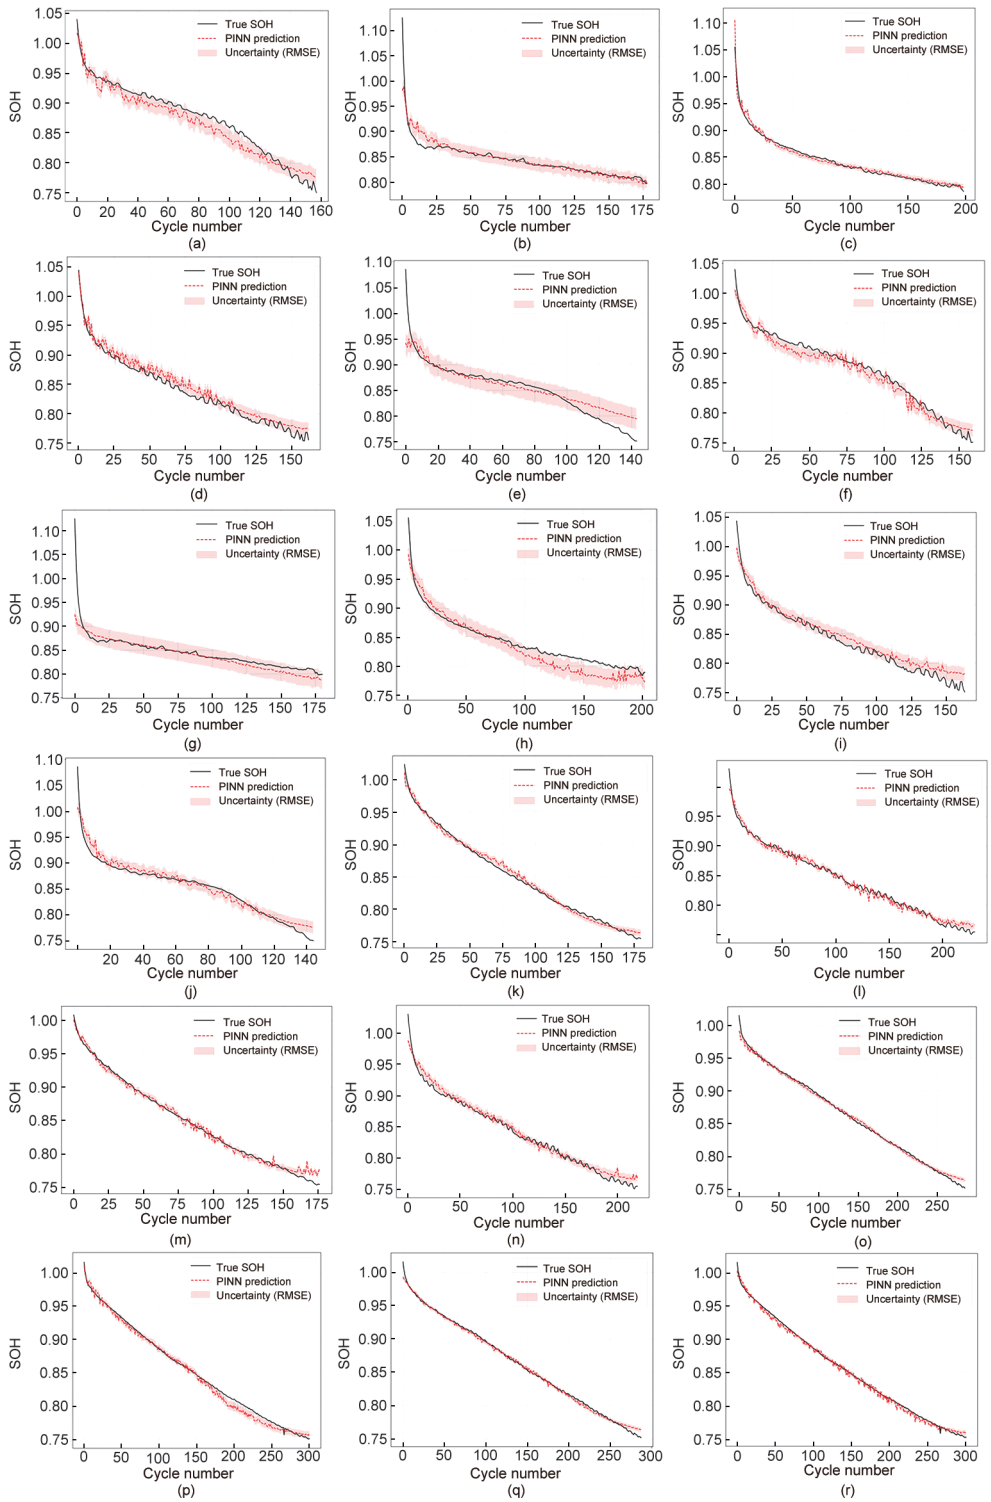


图7　不同温度与SOC工况下的SOH估计结果：(a) 25_CV01；(b) 25_CV02；(c) 25_CV03；(d) 25_CV05；(e) 25_CV06；(f) 25_CI01；(g) 25_CI02；(h) 25_CI03；(i) 25_CI05；(j) 25_CI06；(k) 35_CI01；(l) 35_CI02；(m) 35_CV01；(n) 35_CV02；(o) 45_CI01；(p) 45_CI02；(q) 45_CV01；(r) 45_CV02

Fig. 7　SOH estimation results under different temperatures and SOC conditions: (a) 25_CV01; (b) 25_CV02; (c) 25_CV03; (d) 25_CV05; (e) 25_CV06; (f) 25_CI01; (g) 25_CI02; (h) 25_CI03; (i) 25_CI05; (j) 25_CI06; (k) 35_CI01; (l) 35_CI02; (m) 35_CV01; (n) 35_CV02; (o) 45_CI01; (p) 45_CI02; (q) 45_CV01; (r) 45_CV02

从不同样本的退化轨迹可以看出，各电池SOH衰减过程存在一定差异：部分电池在早期循环阶段出现快速下降，随后进入相对平缓的衰退阶段；部分电池在中后期呈现局部波动或衰减速率变化。尽管不同电池的退化模式并不完全一致，DRT+PINN模型仍能在多数循环区间内保持稳定跟踪，预测曲线与真实曲线之间未出现明显的系统性偏离。这说明基于DRT特征的PINN模型不仅能够学习整体SOH衰减趋势，也能够在一定程度上适应不同工况和不同电池样本之间的退化差异。

浅红色RMSE参考误差带用于直观表征模型预测误差的波动范围。由图可见，大部分真实SOH曲线与预测曲线均位于较接近的区域内，说明模型整体预测误差较小，估计结果具有较好的稳定性。对于个别电池在早期快速衰减或后期波动较明显的区间，预测值与真实值之间存在一定偏差，但整体变化趋势仍保持一致，进一步说明所提方法在复杂老化过程下具有较好的稳定性。

3.2.2 不同健康特征组合对SOH估计性能与模型复杂度的影响

为进一步验证所提取健康特征对SOH估计的有效性，并分析特征筛选对模型精度、训练效率及模型复杂度的影响，本研究设置了3组不同输入特征组合进行对比实验。其中，Features1表示将提取得到的3组共25个特征全部作为模型输入；Features2表示经Pearson相关系数筛选后得到的6个高相关性特征；Features3则是在Features2的基础上进一步去除高度共线性特征Peak_1_Rel_Height和Peak_4_Height后得到的4个特征。3组特征分别输入PINN模型进行SOH估计，训练参数保持一致，epochs为800，batch_size为30，实验结果如表4所示。

由表4可知，Features1在训练集上取得了最低的RMSE和MAPE，分别为0.261%和0.223%，表明增加输入特征数量有助于模型更充分地拟合训练数据。然而，在测试集上，Features1的RMSE为0.594%，略高于Features2的0.568%，说明全部特征中可能存在一定冗余信息，过多输入特征并未进一步提升模型的泛化能力。相比之下，Features2在测试集上取得了最低的RMSE，同时训练时间由Features1的129.863 s降低至118.567 s，模型大小也由259 KB减小至234 KB，说明经过相关性筛选后的6个健康特征能够在减少模型复杂度的同时保持较好的SOH估计精度。

对于Features3，虽然其进一步减少了输入特征数量，模型大小降低至231 KB，但测试集RMSE和MAPE分别增大至1.110%和0.801%，预测精度明显下降。这表明Peak_1_Rel_Height和Peak_4_Height虽与其他特征存在较强共线性，但仍包含与电池退化相关的有效信息，直接剔除会削弱模型对SOH变化规律的表征能力。综合精度、训练时间和模型大小可知，Features2在模型泛化性能和计算效率之间取得了较优平衡，因此本研究最终选取经Pearson相关系数筛选后的6个健康特征作为后续SOH估计模型的输入。

表4 不同输入特征组合下PINN模型的SOH估计性能与计算开销对比

Table 4 Comparison of SOH estimation performance and computational cost of the PINN model under different input feature combinations

输入特征组合	Features1		Features2		Features3	
	训练集	测试集	训练集	测试集	训练集	测试集
RMSE/%	0.261	0.594	0.472	0.568	0.892	1.110
MAPE/%	0.223	0.364	0.600	0.749	0.702	0.801
训练耗时/s	129.863		118.567		134.967	
模型存储开销/KB	259		234		231	

3.2.3 不同SOH估计模型的性能对比分析

为进一步验证本研究所提出PINN模型在SOH估计任务中的有效性，本研究基于筛选得到的高相关性DRT健康特征，构建多层感知器（multilayer perceptron，MLP）、卷积神经网络（convolutional neural network，CNN）、长短期记忆网络（long short-term memory，LSTM）、GPR、Transformer和XGBoost 6种典型数据驱动模型作为对比模型，并与所提出的PINN模型进行性能比较。各模型均采用相同的输入特征和数据划分方式，以SOH作为预测目标。其中，MLP采用4层全连接神经网络结构，隐藏层节点数依次为256、128、64和32，激活函数为Sigmoid；CNN采用2层一维卷积网络，卷积核数量分别为64和128，并结合批归一化、最大池化层和全局平均池化层提取局部特征；LSTM采用长度为5的时间窗口构建序列输入，设置2层LSTM网络，隐藏单元数分别为64和32，以学习电池退化过程中的时序特征；GPR采用高

斯过程回归模型，以Matern核函数、常数核函数和白噪声核函数构建协方差矩阵，实现非参数概率回归；Transformer模型首先对输入特征进行嵌入编码，然后通过多头自注意力机制和前馈神经网络提取全局特征信息，最终完成SOH回归预测；XGBoost采用梯度提升决策树框架，通过多棵回归树的集成学习实现SOH估计。相比之下，本研究提出的PINN模型在深度神经网络基础上引入电池退化物理约束和单调性约束，实现数据驱动与机理信息的融合建模。各模型均采用训练集和测试集上的MAPE与RMSE作为评价指标，实验结果如表5所示。

由表5可知，本研究所提出的PINN模型在测试集上取得了最优的预测结果，其MAPE和RMSE分别为0.568%和0.749%，均低于其他对比模型。与MLP、CNN、LSTM、GPR、Transformer和XGBoost相比，PINN模型的测试集MAPE分别降低了70.39%、67.73%、64.28%、63.82%、67.36%和70.69%，测试集RMSE分别降低了69.52%、66.23%、52.35%、62.88%、64.77%和69.33%。结果表明，在相同DRT健康特征输入条件下，PINN模型能够更准确地刻画电池退化规律，从而获得更高的SOH估计精度。

表5　不同SOH估计模型的预测精度对比

Table 5　Comparison of SOH Estimation Accuracy of Different Models

方法	PINN		MLP		CNN		LSTM		GPR		Transformer		XGBoost	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
MAPE/%	**0.472**	**0.568**	0.864	1.918	1.320	1.760	1.110	1.590	0.770	1.570	1.283	1.740	0.481	1.938
RMSE/%	0.600	**0.749**	0.945	2.457	1.628	2.218	1.283	1.572	0.950	2.018	1.562	2.126	**0.547**	2.442

从训练集结果来看，XGBoost在训练集上的RMSE为0.547%，略低于PINN的0.600%，且其训练集MAPE为0.481%，与PINN的0.472%接近。然而，XGBoost在测试集上的MAPE和RMSE分别升高至1.938%和2.442%，表现出较明显的泛化性能下降。类似地，MLP、CNN和Transformer在训练集与测试集之间也存在较大的误差差异，说明纯数据驱动模型在样本规模有限、工况差异较大的情况下更容易受到数据分布变化的影响。其中，MLP仅依赖全连接网络建立输入与输出之间的映射关系，缺乏对退化规律的约束；CNN虽然能够提取局部特征，但对长期退化趋势的建模能力有限；Transformer具有较强的全局特征学习能力，但对训练数据规模较为敏感；XGBoost能够获得较好的训练拟合效果，但在复杂退化场景下容易出现泛化能力不足的问题。相比之下，LSTM和GPR在测试集上的表现相对稳定，说明时序建模能力和概率回归机制能够在一定程度上提升预测鲁棒性，但其整体精度仍低于PINN模型。

造成上述结果的主要原因在于，MLP、CNN、LSTM、GPR、Transformer和XGBoost主要依赖输入特征与SOH之间的统计映射关系，而本研究所提出的PINN模型在数据损失的基础上进一步引入了物理约束项和退化单调性约束，使模型在学习非线性映射关系的同时受到电池退化机理的约束。通过将数据驱动学习与物理先验知识相结合，PINN能够有效减少模型对训练样本的过度依赖，提高模型对未知工况和未见样本的适应能力。因此，PINN模型能够有效降低纯数据驱动模型的过拟合风险，从而提高SOH估计的稳定性和预测精度。

综合来看，本研究所提出的PINN模型在多模型对比实验中表现出最优的测试集预测性能，在多温度、多SOC工况下表现出较好的估计稳定性，验证了将电池退化机理与深度学习模型相结合在锂离子电池SOH估计中的有效性。

4　结　论

针对锂离子电池SOH估计中EIS特征耦合严重、DRT求解易受伪峰干扰以及传统数据驱动模型泛化能力不足等问题，本研究提出了一种融合改进型弛豫时间分布与物理信息神经网络的SOH估计方法。首先，构建了包含高频电感和低频恒相位元件修正项的DRT阻抗模型，并基于轻量化数值解算策略实现了EIS频域信息向弛豫时间尺度域的转换，有效提取了能够反映电池老化状态变化的多时间尺度健康特征。其次，通过Pearson相关性分析和VIF共线性检验，筛选出与SOH高度相关且具有较低输入维度的特征组合，在保证模型精度的同时降低了计算复杂度。最后，将筛选后的DRT健

康特征输入PINN模型，并在损失函数中引入电池退化动力学约束和单调性约束，实现了数据驱动学习与物理先验信息的融合。

实验结果表明，本方法在不同温度、不同SOC及不同老化阶段下均表现出较好的SOH估计能力。与直接提取EIS物理特征的EIS+PINN方法相比，DRT+PINN在多数工况下取得更低的RMSE和MAPE，说明DRT特征能够更有效地表征阻抗谱中的退化信息。与MLP、CNN、LSTM、GPR、Transformer和XGBoost等对比模型相比，所提方法在测试集上获得了更优的预测精度和泛化表现，验证了DRT特征与物理约束神经网络融合建模的有效性。

需要指出的是，本研究仍存在一定局限性。首先，实验数据主要来源于同一公开EIS老化数据集，电池样本在材料体系、规格参数和测试平台方面相对一致，尚未充分覆盖LFP、NCM、LCO等不同正负极材料体系，以及不同容量规格、不同制造厂家的电池样本。因此，所提方法在跨化学体系、跨规格电芯和跨厂家数据条件下的泛化能力仍需进一步验证。其次，本研究所采用的数据主要来自实验室标准测试条件，虽然覆盖了不同温度、SOC和老化阶段，但尚未引入真实车载动态工况下的在线EIS数据，复杂电流扰动、温度波动、测量噪声及工况快速切换对DRT特征稳定性和PINN估计性能的影响仍有待深入分析。再次，本研究改进DRT模型主要通过分频域参数计算和正则化约束抑制伪峰干扰，已在现有多工况数据上取得较稳定的拟合结果，但对于低温环境、强噪声阻抗谱及严重畸变EIS数据下的伪峰消除效果仍需开展更系统的特例测试。未来工作将进一步采集多材料体系、多温度区间、多老化路径及真实车载运行条件下的EIS数据，并结合跨数据集验证、在线测试和嵌入式部署实验，进一步评估和提升所提方法的泛化能力、抗干扰能力和工程应用价值。

符 号 说 明

f—— 频率
j—— 单位虚数
L—— 电感
Q—— CPE元件常数
R—— 电阻
Z—— 阻抗
π—— 圆周率
α—— CPE元件指数
τ—— 弛豫时间
$\gamma\ln(\tau)$—— 弛豫时间分布函数
Θ、Φ—— 神经网络模型参数
λ、β—— 损失函数超参数
δ—— 正则化参数

参 考 文 献

[1] BIAN J W, LIU G, CHEN J W, et al. PSO-MLSt-LSTM: Multi-layer stacked ensemble model for lithium-ion battery SOH prediction *via* multi-feature fusion[J]. Journal of Energy Storage, 2025, 125: 116825. DOI:10.1016/j.est.2025.116825.

[2] KURUCAN M, ÖZBALTAN M, YETGIN Z, et al. Applications of artificial neural network based battery management systems: A literature review[J]. Renewable and Sustainable Energy Reviews, 2024, 192: 114262. DOI:10.1016/j.rser.2023.114262.

[3] YANG Y S, ZHAO L J, YU Q Q, et al. State of charge estimation for lithium-ion batteries based on cross-domain transfer learning with feedback mechanism[J]. Journal of Energy Storage, 2023, 70: 108037. DOI:10.1016/j.est.2023.108037.

[4] YANG Y L, CHEN S Y, CHEN T, et al. State of health assessment of lithium-ion batteries based on deep Gaussian process regression considering heterogeneous features[J]. Journal of Energy Storage, 2023, 61: 106797. DOI: 10.1016/j. est. 2023. 106797.

[5] ZHOU D H, WANG B, ZHU C, et al. A light-weight feature extractor for lithium-ion battery health prognosis[J]. Reliability Engineering & System Safety, 2023, 237: 109352. DOI:10.1016/j. ress.2023.109352.

[6] 王志福, 张顺顺, 罗崴, 等. 锂离子电池荷电状态与健康状态联合估计策略研究综述[J]. 科学技术与工程, 2025, 25(25): 10537-10550.
WANG Z F, ZHANG S S, LUO W, et al. Review of joint SOC and SOH estimation strategies for lithium-ion battery[J]. Science Technology and Engineering, 2025, 25(25): 10537-10550.

[7] 王聪, 陈云霞, 王烽, 等. 变温度工况下锂离子电池健康状态退化预测[J]. 机械工程学报, 2026, 62(10): 273-285.
WANG C, CHEN Y X, WANG F, et al. State of health degradation prediction of lithium-ion batteries under variable temperature conditions[J]. Journal of Mechanical Engineering, 2026, 62(10): 273-285.

[8] 崔树辉, 周贺, 黄振兴, 等. 动力电池梯次利用关键技术与应用综述[J]. 广东电力, 2023, 36(1): 9-19.
CUI S H, ZHOU H, HUANG Z X, et al. Review of key technologies and applications of echelon utilization of power batteries[J]. Guangdong Electric Power, 2023, 36(1): 9-19.

[9] RANQUE P, GONZALO E, ARMAND M, et al. Performance-based materials evaluation for Li batteries through impedance spectroscopy: A critical review[J]. Materials Today Energy, 2023, 34: 101283. DOI:10.1016/j.mtener.2023.101283.

[10] WANG J, ZHAO R, HUANG Q A, et al. High-efficient prediction of state of health for lithium-ion battery based on AC impedance feature tuned with Gaussian process regression[J]. Journal of Power Sources, 2023, 561: 232737. DOI: 10.1016/j. jpowsour. 2023.232737.

[11] LI H L, WEI W, LIU F X, et al. Identification of internal polarization dynamics for solid oxide fuel cells investigated by electrochemical impedance spectroscopy and distribution of relaxation times[J]. Energy, 2023, 267: 126482. DOI: 10.1016/j. energy.2022.126482.

[12] CHEN X, LI L Y, LIU M M, et al. Detection of lithium plating in lithium-ion batteries by distribution of relaxation times[J]. Journal of Power Sources, 2021, 496: 229867. DOI: 10.1016/j. jpowsour. 2021.229867.

[13] HUANG J, SULLIVAN N P, ZAKUTAYEV A, et al. How reliable is distribution of relaxation times (DRT) analysis? A dual regression-classification perspective on DRT estimation, interpretation, and accuracy[J]. Electrochimica Acta, 2023, 443: 141879. DOI: 10. 1016/j.electacta.2023.141879.

[14] EFFENDY S, SONG J, BAZANT M Z. Analysis, design, and generalization of electrochemical impedance spectroscopy (EIS) inversion algorithms[J]. Journal of the Electrochemical Society, 2020, 167(10): 106508. DOI:10.1149/1945-7111/ab9c82.

[15] LIU X Y, ZHANG X Q, CHEN X, et al. A generalizable, data-driven online approach to forecast capacity degradation trajectory of lithium batteries[J]. Journal of Energy Chemistry, 2022, 68: 548-555. DOI:10.1016/j.jechem.2021.12.004.

[16] SU Z P, LAI J D, SU J H, et al. Modeling and health feature extraction method for lithium-ion batteries state of health estimation by distribution of relaxation times[J]. Journal of Energy Storage, 2024, 90: 111770. DOI:10.1016/j.est.2024.111770.

[17] 于天剑, 曾笑颜, 冯恩来, 等. 基于LSTM-Transformer多通道特征融合的锂电池SOC-SOH联合估计[J]. 铁道科学与工程学报, 2026, 23 (1): 301-313.
YU T J, ZENG X Y, FENG E L, et al. A joint estimation of SOC-SOH for lithium batteries based on LSTM-Transformer multi-channel feature fusion[J]. Journal of Railway Science and Engineering, 2026, 23(1): 301-313.

[18] CHEN Z, LIU Y, SUN H. Physics-informed learning of governing equations from scarce data[J]. Nature Communications, 2021, 12: 6136. DOI:10.1038/s41467-021-26434-1.

[19] ZHANG Y W, TANG Q C, ZHANG Y, et al. Identifying degradation patterns of lithium ion batteries from impedance spectroscopy using machine learning[J]. Nature Communications, 2020, 11: 1706. DOI:10.1038/s41467-020-15235-7.

[20] WANG F J, ZHAI Z, ZHAO Z B, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis[J]. Nature Communications, 2024, 15: 4332. DOI: 10.1038/s41467-024-48779-z.

[21] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J]. 高电压技术, 2024, 50(3): 1182-1195.
XIONG Q, DI Z G, JI S C. Review on health state estimation and life prediction of lithium-ion batteries[J]. High Voltage Engineering, 2024, 50(3): 1182-1195.

[22] 王佳, 黄秋安, 李伟恒, 等. 电化学阻抗谱弛豫时间分布基础[J]. 电化学, 2020, 26(5): 607-627.
WANG J, HUANG Q A, LI W H, et al. Fundamentals of distribution of relaxation times for electrochemical impedance spectroscopy[J]. Journal of Electrochemistry, 2020, 26(5): 607-627.

[23] 严芷涵, 王学远, 魏学哲, 等. 基于电化学阻抗谱几何解析的锂离子电池健康状态评估[J]. 储能科学与技术, 2025, 14(12): 4732-4742.
YAN Z H, WANG X Y, WEI X Z, et al. State-of-health estimation for lithium-ion batteries using geometric analysis of electrochemical impedance spectroscopy[J]. Energy Storage Science and Technology, 2025, 14(12): 4732-4742.

[24] 王萍, 弓清瑞, 张吉昂, 等. 一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J]. 电工技术学报, 2021, 36(24): 5201-5212.
WANG P, GONG Q R, ZHANG J A, et al. An online state of health prediction method for lithium batteries based on combination of data-driven and empirical model[J]. Transactions of China Electrotechnical Society, 2021, 36(24): 5201-5212.

[25] ZHANG Q, WANG D F, SCHALTZ E, et al. Degradation mechanism analysis and state-of-health estimation for lithium-ion batteries based on distribution of relaxation times[J]. Journal of Energy Storage, 2022, 55: 105386. DOI: 10.1016/j. est. 2022. 105386.

[26] XU B L, OUDALOV A, ULBIG A, et al. Modeling of lithium-ion battery degradation for cell life assessment[J]. IEEE Transactions on Smart Grid, 2018, 9(2): 1131-1140. DOI: 10.1109/tsg. 2016. 2578950.

[27] 刘宁宁, 王渠, 王炤东, 等. 多特征数据驱动的锂金属电池健康状态估计方法研究[J]. 机械工程学报, 2026, 62(6): 346-358.
LIU N N, WANG J, WANG Z D, et al. Multi-feature fusion approach for data-driven state of health estimation in lithium-metal batteries[J]. Journal of Mechanical Engineering, 2026, 62 (6): 346-358.

[28] XU H M, YU T J, FENG E L, et al. A lithium-ion battery state-of-health prediction model based on physical information constraints and multimodal feature fusion[J]. Journal of Central South University, 2025, 32(11): 4593-4612.

[29] JIANG B, ZHU J G, WANG X Y, et al. A comparative study of different features extracted from electrochemical impedance spectroscopy in state of health estimation for lithium-ion batteries [J]. Applied Energy, 2022, 322: 119502. DOI: 10.1016/j. apenergy.2022.119502.