



基于物理信息神经网络的锂离子电池荷电状态估计研究综述

王顺利¹, 张文霞¹, 郭子文¹, 邓 潇¹, 刘广忱¹, 黄 琦²

(¹内蒙古工业大学电力学院, 内蒙古 呼和浩特 010000; ²西南科技大学信息工程学院, 四川 绵阳 621010)

摘 要: 锂离子电池荷电状态 (state of charge, SOC) 的精确估计是电池管理系统 (battery management system, BMS) 实现安全管控与高效调度的关键挑战。电池内在的强非线性、时变参数与复杂外部工况, 使得传统方法面临固有局限: 模型驱动方法在参数失配时精度骤降, 而纯数据驱动方法则受制于数据依赖性强与物理一致性缺失的风险。物理信息神经网络 (physics-informed neural networks, PINN) 作为一种“机理嵌入”的新范式, 通过将等效电路模型或电化学模型等电池物理模型的控制方程作为正则化约束嵌入损失函数, 为应对上述挑战提供了创新解决方案。本综述详细介绍了 PINN-SOC 估计器的理论框架与设计路径, 并通过与基于物理驱动方法、基于数据驱动方法、“数据-物理”融合方法系统性对比分析, 结果表明 PINN 方法能够将 SOC 估计的均方根误差 (root mean square error, RMSE) 稳定在较低区间, 且在未知工况下仍保持良好的精度和泛化性能。尽管优势显著, PINN 方法的工程化应用仍面临训练稳定性、损失权重平衡与计算效率等挑战。未来的研究有望通过发展自适应训练算法与轻量化网络结构等关键技术, 逐步克服现有瓶颈, 推动 PINN 成为下一代智能 BMS 的最佳估计方案。

关键词: 物理信息神经网络; 锂离子电池; 荷电状态估计; 电池建模; 机理与数据融合

doi: 10.19799/j.cnki.2095-4239.2025.1047

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2026) 06-2319-19

Review of lithium-ion battery state of charge estimation based on physics-informed neural networks

WANG Shunli¹, ZHANG Wenxia¹, GUO Ziwen¹, DEND Xiao¹, LIU Guangchen¹, HUANG Qi²

(¹Electric Power College, Inner Mongolia University of Technology, Hohhot 010000, Inner Mongolia, China;

²School of Information Engineering, Southwest University of Science and Technology, Mianyang 621010, Sichuan, China)

Abstract: Estimating the state of charge (SOC) for lithium-ion batteries is a critical challenge for enabling battery-management systems (BMSs) to achieve safe control and efficient scheduling. The strong inherent non-linearity and time-varying parameters within batteries, coupled with complex external operating conditions, impose inherent limitations on traditional approaches: model-driven methods experience a sharp decline in accuracy when parameters are mismatched, while purely data-driven methods are constrained by high data dependency and the risk of lacking physical consistency. Physics-informed neural networks (PINNs)

收稿日期: 2025-11-19; 修改稿日期: 2025-12-18。

基金项目: 国家重点研发计划 (2024YFB2408400), 国家自然科学基金 (62173281, 52377217, U23A20651), 四川省自然科学基金 (2024NSFSC0013)。

第一作者及通信联系人: 王顺利 (1985—), 男, 教授, 博士生导师, 从事新能源与储能系统研究, E-mail: 497420789@qq.com。

引用本文: 王顺利, 张文霞, 郭子文, 等. 基于物理信息神经网络的锂离子电池荷电状态估计研究综述[J]. 储能科学与技术, 2026, 15(6): 2319-2337.

Citation: WANG Shunli, ZHANG Wenxia, GUO Ziwen, et al. Review of lithium-ion battery state of charge estimation based on physics-informed neural networks[J]. Energy Storage Science and Technology, 2026, 15(6): 2319-2337.

represent a novel paradigm for embedding physical mechanisms. This approach offers an innovative solution to the aforementioned challenges by embedding the governing equations of battery physics models, such as equivalent-circuit models or electrochemical models, as regularization constraints within the loss function. In this review, we introduce the theoretical framework and design methodology of the PINN-SOC estimator in detail. A systematic comparative analysis with physics-driven, data-driven, and data-physics hybrid approaches demonstrates that the PINN method consistently maintains the root mean square error of SOC estimation within a low range, while retaining high accuracy and the capability for generalization under unknown operating conditions. Despite these notable strengths, the engineering application of the PINN method still faces challenges, such as the issues of training stability, weight-loss balancing, and computational efficiency. We expect future research to overcome existing bottlenecks gradually by developing key technologies, like adaptive-training algorithms and lightweight network architectures, thus positioning PINNs as the optimal solution for next-generation intelligent BMS.

Keywords: physical information neural network; lithium-ion battery; state of charge estimation; battery modeling; mechanism and data fusion

锂离子电池凭借高能量密度、长循环寿命和低自放电率等优势,已成为推动新能源汽车、智能电网等战略性新兴产业发展的核心能源载体^[1-2],其性能优化与安全管理是能源清洁化转型中的关键技术挑战。**BMS**作为保障系统安全高效运行的技术基石,其核心功能——**SOC**的精确估计,直接决定了系统的安全边界、能量调度与寿命预测效能,具有决定性意义^[3]。然而,实现**SOC**的精准估计面临着严峻挑战。电池作为复杂电化学系统,其强非线性、时变及老化特性导致模型易失配^[4-5];加之实际工况复杂、数据稀疏与测量噪声等问题,则对算法的自适应性及鲁棒性提出极高要求^[6]。这些因素共同催生了对于能够深度融合机理与数据的新一代估计方法的迫切需求。目前,现存的锂电池**SOC**估计方法主要可分为以下三大类:基于模型驱动方法、基于数据驱动方法以及“模型-数据”简单融合方法,各研究方法及其优势分析如图1所示。

基于模型驱动方法的核心思想是利用电池数学模型,结合状态估计算法通过外部变量推断内部状态。卡尔曼滤波算法在众多状态观测器中发挥了极其重要的作用。扩展卡尔曼滤波(**extended Kalman filter, EKF**)通过一阶泰勒展开处理非线性系统,它实现了**SOC**的最小均方误差估计,但在强非线性或模型不精确时估计精度下降。**Xie**等人^[7]基于二阶**RC**等效电路模型,研究了基于扩展

卡尔曼滤波算法对锂离子荷电状态的估计,有效解决了常用卡尔曼滤波算法对噪声的敏感性强的问题。无迹卡尔曼滤波(**unscented Kalman filter, UKF**)采用了无迹变换有效解决了**EKF**存在线性化误差问题,其精度通常优于**EKF**,尤其适用于非线性较强的场。**Liu**等人^[8]提出平方根无迹卡尔曼滤波(**square root UKF algorithm, SR-UKF**)构建复杂条件和环境下的**SOC**估计,结果表明该方式可以增强滤波器的鲁棒性。此外,研究者们还提出自适应扩展/无迹卡尔曼滤波及双卡尔曼滤波等,以应对模型参数时变和噪声统计特性未知等问题。**Wu**等人^[9]基于二阶**RC**等效电路模型,提出次优多重渐消因子扩展卡尔曼滤波(**suboptimal multiple fading factor extended Kalman filter, SMFEKF**)方法,有效解决了在**SOC**初始值不确定情况下准确预测的问题。**Solomon**等人^[10]提出了一种改进的分数阶扩展卡尔曼滤波器有效提升了**SOC**估计精度。然而,基于模型驱动的性能严重依赖于电池模型的精度,且模型参数随温度、老化度和**SOC**剧烈变化,模型参数辨识困难,难以适应电池老化和复杂工况的变化^[11-13]。

数据驱动方法的核心思想是摆脱对电池内部复杂化学机理的建模,直接从电压、电流、温度等历史数据中学习其与**SOC**的映射关系^[14]。早期研究多采用支持向量机、高斯过程回归等传统机器学习




图1 现存的锂电池SOC估计方法及分析

Fig. 1 Existing lithium-ion battery SOC estimation methods and analysis

算法^[15]，这些方法在小样本且特征工程得当时有效，但难以捕捉电池动态特性的长时序依赖，且依赖繁琐的人工特征工程^[16-17]。正是由于传统数据驱动方法的局限性，研究重点转向具备端到端学习和强大时序动态刻画能力的深度学习，为解决电池SOC估计中的挑战提供了新的可能^[18]。Zhang等人^[19]提出了一种双循环神经网络的SOC在线估计方法，分别负责长、短时间尺度的参数更新与状态估计。Wang等人^[20]针对小目标样本集，提出了一种基于改进的门控循环单元（gated recurrent unit, GRU）的迁移学习SOC估计方法，实现了快速准确的SOC估计。尽管深度学习在时序建模方面取得了显著进展，但其性能高度依赖于大规模高质量标注数据，模型在训练数据分布之外的工况下泛化能力不足^[21]。更关键的是，其“黑箱”特性导致预测结果无法保证满足物理规律，可能在安全攸关的电池管理系统中产生不合理结果，潜藏巨大风险^[22]。

基于“模型-数据”简单融合方法的核心在于将前两种方法串联或并联把它们的优势结合起来，以提高SOC估计结果的准确性和鲁棒性。并联式

融合利用数据驱动模型对机理模型的输出残差进行学习和补偿^[23]。Ahn等人^[24]提出并联双长短期记忆网络（long short-term memory, LSTM）结构，分别捕获宏观趋势与动态突变，在融合层整合输出，以提升低温等非线性工况下的精度。而串联式融合则将机理模型作为预处理手段，用于扩充数据驱动模型的输入特征。Takyi-Aninakwa等人^[25]将自适应UKF的输出向量作为LSTM的扩展输入，获得了比仅采用LSTM模型更好的SOC估计结果。尽管这些融合策略在特定场景下展现出比单一方法更好的性能，证明了结合机理与数据的初步价值，但它们本质上仍是一种表层的融合，存在根本性的局限。其融合逻辑多依赖于启发式或经验性设计，参数常需繁琐的人工调优，且难以自适应变化的工作条件。更重要的是，此类方法并未实现机理与数据的深度内在耦合，物理信息仅作为模型的输入或补偿，未能将电池运行的内在物理规律以严格的数学形式嵌入到学习核心中，因而无法从根本上保证估计结果的物理合理性与泛化能力。

在此背景下，PINN作为一种深度“机理与数

据融合”新范式应运而生,为解决SOC估计的瓶颈问题提供了创新思路。PINN算法的核心思想是将偏微分方程嵌入神经网络的训练过程中,驱使模型输出在拟合数据的同时严格遵循物理规律,从而在数据稀疏条件下仍能保证解的物理合理性^[26-27]。Nascimento等人^[28]利用简化电化学模型作为物理信息基础,通过循环神经网络直接求解控制方程,并结合浅层多层感知机(multilayer perceptron, MLP)与贝叶斯更新,实现了在少量数据下的SOC/SOH联合高精度估计。Wang等人^[29]则创新地将电池电化学阻抗谱(electrochemical impedance spectroscopy, EIS)特性与Caputo分数阶导数嵌入循环神经网络,仅通过梯度级物理注入即实现了SOC估计误差小于2%的优异性能,无需复杂的偏微分方程(partial differential equation, PDE)残差计算。以上研究表明PINN算法在锂电池SOC估计领域具有巨大的潜力,能够深度耦合物理机理与数据驱动,显著提升估计精度与泛化能力,此外, PINN在处理高维偏微分方程方面的能力,使其有望应用于基于详细电化学模型的内部状态可视化,为电池机理研究和健康状态监测提供新的技术手段。这些独特优势使得PINN成为下一代智能电池管理系统中状态估计算法的有力候选者。

本文围绕PINN方法应用于锂离子电池荷电状态估计展开系统述评。第1部分将阐述物理信息神经网络与电池建模的基础理论;第2部分系统构建基于PINN的SOC估计器设计框架;第3部分通过对比分析论证PINN方法的优势与特性;第4部分剖析当前挑战并展望未来研究方向。全文旨在为PINN在电池状态估计领域的深入研究提供系统参考。

1 PINN与电池建模的融合理论框架构建

1.1 物理信息神经网络的方法论核心思想

PINN的核心思想是通过将描述物理系统的控制方程嵌入神经网络的学习过程,使网络在训练过程中同时满足数据拟合和物理规律约束的双重要求。该方法基于神经网络的通用逼近定理,通过自动微分(automatic differentiation, AD)技术高效计算网络输出对输入的偏导数,进而构造物理方程的残差项并融入损失函数^[30-31]。在优化策略方面,

PINN采用多目标损失函数设计,由数据拟合损失 L_{data} 和物理约束损失 $L_{physics}$ 加权构成^[32],总损失函数具体表达如式(1)所示。

$$L_{total} = \lambda_{data} L_{data} + \lambda_{physics} L_{physics} \quad (1)$$

式中, λ_{data} 和 $\lambda_{physics}$ 分别表示数据损失函数和物理损失函数的加权超参数,通过超参数的优化过程实现了数据驱动与物理约束的最佳平衡。这种“数据驱动+物理约束”的机制,使PINN在数据稀疏区域能通过物理规律进行合理外推,在数据丰富区域能精细拟合非线性动态,从而在保证物理一致性的前提下实现高精度建模与状态估计。然而,其应用效果高度依赖于所嵌入物理知识本身的准确性与适用性。因此,在深入探讨PINN-SOC估计器的设计之前,必须系统回顾并理解锂离子电池的建模基础与其核心挑战。

1.2 锂离子电池建模范式的梳理与局限性分析

电池模型是状态估计的基石,其精度与复杂度决定了SOC估计方法的性能上限。当前建模方法主要分为基于外部特性的等效电路模型和基于内部机理的电化学模型两大范式。本节将系统梳理这两类模型在SOC估计中的应用现状,并深入剖析其固有局限性,旨在为后续阐述PINN这一新型融合范式奠定问题基础。

ECM通过电阻、电容等电路元件模拟电池的外部特性,根据模型复杂度,ECM可分为Rint模型、戴维宁模型、PNGV模型以及多阶RC等效电路模型^[33-34],其优劣势比较如表1所示。

在上述的ECM中,戴维宁模型和二阶RC等效电路模型因在复杂度与精度间取得良好平衡而应用最广。其动态特性可由一组简单的状态空间方程描述,这种线性化形式使其非常适合与卡尔曼滤波类算法结合,实现SOC的在线估计^[35]。然而,等效电路模型存在本质局限性。首先,ECM的参数 R_0 , R_1 , C_1 等具有强烈的时变特性,随温度、SOC工作点、电流倍率及老化状态显著变化^[36]。为应对ECM参数的时变性,研究者尝试将数据驱动方法融入在线辨识。为应对此问题,研究者尝试引入自适应滤波^[37]或LSTM网络动态校正^[38]等方法进行在线参数辨识,这体现了利用数据驱动技术增强模型自适应性的主流方向,为PINN这种将物理模型与数据驱动网络进行耦合的理念的深度融合提供了思

表 1 锂离子电池等效电路模型比较

Table 1 Comparison of lithium-ion battery equivalent circuit models

模型	优点	缺点	准确性
Rint 模型	计算简单	精度较低	差
戴维宁模型	结构简单, 考虑了动态特性	对高频动态或复杂老化工况的拟合精度不足	较好
多阶 RC 等效电路模型	能精确描述电池的多时间常数动态特性	结构较为复杂, 计算量较大	好
PNGV 模型	考虑动态特性及 SOC 变化对 OCV 的影响	结构复杂	较好

路借鉴。其次, ECM 参数缺乏明确的物理意义, 无法揭示电池内部状态变化, 限制了其在健康状态估计等高级功能中的应用^[39]。这种“黑箱”特性促使研究者转向更具机理洞察力的电化学模型。

与 ECM 不同, 电化学模型从电化学基本原理出发, 通过偏微分方程组描述锂离子在电极颗粒内的扩散、界面反应等过程。其参数具有真实的物理意义, 理论上具有更好的外推性和寿命周期适应性^[40-41]。单粒子模型 (single-particle model, SPM) 作为电化学模型的重要简化形式, 通过将每个电极视为一个代表性的球形颗粒, 在保持物理机理清晰性的同时显著降低了计算复杂度^[42]。该模型的核心控制方程为描述固相扩散的 Fick 第二定律, 如式(2)所示。

$$\frac{\partial c_s}{\partial t} = D_s \nabla^2 c_s = \frac{D_s}{r^2} \frac{\partial}{\partial r} \left(r^2 \frac{\partial c_s}{\partial r} \right) \quad (2)$$

式中, c_s 表示固相锂离子浓度, D_s 为固相扩散系数, r 为径向坐标。这一偏微分方程准确刻画了锂离子在电极颗粒内部的扩散动力学过程, 是 SPM 描述电池动态特性的基础^[43-44]。在电极界面, 电化学反应遵循 Butler-Volmer 动力学方程; 而粒子表面通量守恒、中心对称性的边界条件则确保了模型的物理合理性与数学封闭性。最终, SOC 通过电极颗粒的平均锂浓度换算, 如式(3)所示。

$$\text{SOC} = \frac{\bar{c}_s - c_{s,\min}}{c_{s,\max} - c_{s,\min}} \quad (3)$$

式中, $\bar{c}_s$ 表示电极活性材料中锂离子的平均浓度, $c_{s,\min}$ 表示电极材料中锂离子的最小浓度, 即电池完全放电状态的浓度, $c_{s,\max}$ 表示电极材料中锂离子的最大浓度, 即电池完全充电状态的浓度。这一关系将内部状态参数转化为工程可用的状态指标, 为模型的实际应用提供了便利^[45]。通过上述控制方程和边界条件的有机结合, SPM 不仅能够预测电池的外部特性, 还能揭示内部电化学状态的变化规律。近年来, 随着参数自适应机制^[46]与数据驱动方法融合^[47]等技术的引入, SPM 在电池状态估计中的

适用性得到进一步提升。尽管 SPM 具有物理意义明确的优势, 但其在实际应用中面临严峻挑战。首先, SPM 基于一系列简化假设, 如忽略粒子尺寸分布、假设电解液浓度均匀等, 这些假设在高倍率或极端温度工况下会引入显著误差^[48]。其次, SPM 涉及的如固相扩散系数 D_s 、反应速率常数等部分关键参数难以通过实验精确测量, 且这些参数同样会随电池老化而变化, 制约了其在实际 BMS 中的直接应用。

综上所述, ECM 和 SPM 分别从外部特性和内部机理两个角度为电池建模提供了理论基础, 但其各自在参数适应性、计算效率和实用精度方面的局限性, 构成了传统方法在实际应用中的核心瓶颈^[49-50], 这些局限催生了将机理模型与数据驱动方法相融合的新范式。

1.3 PINN 与电池建模的融合机制与创新契机

上述局限性促使研究者探索新的建模范式, 而 PINN 作为一种新兴的“机理与数据融合”方法, 恰好为解决这些挑战提供了可能。传统 ECM 将参数辨识与状态估计分离, 易导致误差累积。PINN 的创新之处在于其联合估计机制, 将 ECM 的物理参数与神经网络的权重参数共同视为可训练变量^[51-52]。通过统一的多目标损失函数, PINN 能利用实时数据同步更新网络权重与物理参数, 实现模型参数的在线自适应与老化跟踪, 避免了繁琐的离线辨识。例如, Sahu 等人^[53]的研究成功地将 Thevenin 等效电路模型的方程作为物理约束嵌入 PINN, 实现了 SOC 与模型参数的同步精确估计, 显著提升了模型在动态工况下的适应性。

对于 SPM 等涉及复杂偏微分方程组的电化学模型, PINN 采用物理信息“软约束”方式^[54-55]。它不直接求解 PDE, 而是将其残差作为损失函数的一部分进行最小化。这种方法使网络能够从参数化解空间中学习满足物理规律的解, 从而降低了对复杂数值求解器的依赖, 也增强了对模型参数初始误差

的鲁棒性。

在实际应用中,电池在全生命周期、全工况下的高质量数据往往稀缺。PINN通过将物理规律嵌入学习过程,为模型提供了内在的正则化和外推合理性^[66]。即使在数据稀疏的区域,其预测结果也被约束在物理规律允许的范围内,从而显著增强了模型的泛化能力。Chen等人^[67]的研究表明,基于PINN的框架在小样本场景下仍可保持SOH估计最大均方

根百分比误差(root mean square percentage error, RMSPE)小于5%。物理信息神经网络融合电池建模范式如图2所示, PINN作为一个核心的融合平台,其上层神经网络接收观测数据,而下层则灵活地嵌入ECM的电路方程或SPM的偏微分方程组作为物理约束。这一架构形象地揭示了PINN如何通过多目标损失函数,实现从外部特性到内部机理的不同电池模型的统一与增强。




图2 PINN融合电池建模范式示意图

Fig. 2 Schematic diagram of the PINN-integrated battery modelling paradigm

综上, PINN并非对传统模型的简单替代,而是通过其联合估计、软约束学习和物理正则化等核心机制,与电池建模的痛点形成了精准的互补关系,为实现高精度、强自适应、强泛化的下一代电池状态估计器提供了强有力的理论框架。

2 基于PINN的SOC估计器设计方法研究

2.1 PINN-SOC估计器的整体架构设计

基于PINN的SOC估计器,其设计核心在于构

建一个融合电池机理与数据驱动能力的智能计算框架。如图3所示,该框架通过将物理约束深度嵌入神经网络,旨在实现高精度、强泛化的电池状态估计。其架构设计主要围绕以下三个环环相扣的核心层面展开。

在输入输出设计方面, PINN-SOC估计器采用多源异构数据融合策略。输入变量主要包括时间变量 t 和工作电流 $I(t)$ ^[58],为提升模型在复杂工况下的适应性,高阶架构还引入温度 T ^[59]、历史工况序列^[60]等多维特征,形成多源异构数据融合的输入空




图3 PINN-SOC估计器基本框架结构

Fig. 3 Basic framework structure of the PINN-SOC estimator

间，遵循了将时空坐标作为网络输入以求解物理问题的通用范式^[61]。在输出端，基础架构输出端电压 V_t 和SOC值，而先进架构扩展到内部状态变量，如锂离子浓度分布 c_s 、过电位 η 等，这种扩展输出策略显著增强了状态估计的丰富性和实用性。

在可训练参数设计方面，PINN-SOC估计器采用双重参数优化策略。一方面优化神经网络权重参数 θ 以学习输入输出的非线性映射关系。另一方面，电池模型的物理参数，如等效电路模型中的欧姆内阻 R_0 或电化学模型中的固相扩散系数 D_s ，通过物理约束的嵌入实现协同优化^[62]。这种双重参数优化机制有效解决了传统方法的固有问题。

PINN-SOC估计器在网络架构的演进上，呈现出从静态拟合到动态关系建模的清晰趋势。早期研究采用全连接神经网络处理静态数据，而最新研究引入了循环神经网络以捕捉时间依赖特性^[63]，甚至采用图神经网络实现多电芯状态的协同估计^[64]。为保障这一复杂框架的训练稳定性与效率，分层训练^[65]、自适应加权^[66]等创新优化策略也应运而生。物理约束的嵌入方式也呈现多样化：包括通过修改网络架构直接满足边界条件的硬约束^[67]和通过损失函数惩罚物理偏差的软约束^[68]。

综上所述，PINN-SOC估计器通过创新的架构

设计，成功实现了物理机理与数据驱动的深度融合。其双重参数优化机制和多目标约束框架，为发展高精度、强鲁棒的下一代电池状态估计器奠定了坚实的基础。

2.2 物理约束与数据驱动的损失函数融合策略

损失函数的设计是PINN框架实现其核心思想的关键环节，其通过多目标优化将数据驱动方法与物理机理约束有机结合，而基于PINN的SOC估计器性能在很大程度上取决于损失函数的合理构建。

2.2.1 数据损失函数构建

数据损失项是连接模型预测与实验观测的桥梁，其根本目的在于最小化网络预测与实验测量之间的差异，为物理约束的引入提供可靠的拟合基准。在SOC估计中，该损失项主要作用于端电压的拟合，通常采用均方误差（mean squared error, MSE）作为准则，以保证对观测数据的基本拟合精度^[69]。但在实际应用过程中，数据损失的设计还需要考虑测量噪声的影响。此外针对动态工况下的数据非均匀分布问题，自适应采样策略通过重点优化关键工况区间的数据点，能够显著提升估计精度^[70]。

2.2.2 物理损失函数构建

物理损失项是PINN区别于纯数据驱动方法的精髓，它通过将电池模型的控制方程作为软约束嵌

入损失函数,驱使网络解满足物理规律^[68,71-72]。根据所采用的电池模型不同,物理损失的具体形式存在显著差异。对于ECM模型,物理损失主要来源于状态方程的残差,其形式简洁且计算高效;而基于电化学模型的物理损失则更为复杂,例如SPM模型,涉及包括固相扩散偏微分方程残差和相应的边界条件残差,虽能更精确描述内部机理,但其训练复杂度显著增加。这种差异体现了精度与效率的固有权衡,在实际应用中需根据具体需求选择合适模型。尽管模型复杂度不同,但二者均需通过多目标融合策略实现与数据损失的协同优化。多目标损失函数的融合策略是PINN训练的关键技术,由于固定超参数 λ 难以平衡不同损失项的动态变化,因此常常使用自适应加权算法通过动态调整各损失项的权重来解决训练过程中梯度不平衡问题^[73],具体表达如式(4)所示。

$$\lambda_i^{(k)} = \frac{E[\|\nabla_{\theta} L_i^{(k-1)}\|]}{\sum_j E[\|\nabla_{\theta} L_j^{(k-1)}\|]} \quad (4)$$

式中, $\lambda_i^{(k)}$ 表示第 k 次迭代中第 i 项损失函数的权重,是保障PINN中复杂物理约束与数据拟合目标能够协同收敛的关键。然而,这一机制的效果在很大程度上依赖于初始迭代的梯度状态,因此对初始值较为敏感,在实际应用中需要谨慎初始化以避免训练过程过早陷入局部最优或发散。

总之,损失函数的构建是PINN-SOC估计器设计的核心环节,其多目标优化框架成功实现了数据驱动与物理约束的有机统一。随着自适应加权算法、渐进式训练策略等新技术的发展,损失函数的优化效率和应用效果将得到进一步提升。

2.3 基于PINN的状态-参数一体化估计

PINN在电池状态估计中的核心优势在于其独特的联合估计机制。该机制通过优化统一的损失函数,同步优化神经网络权重参数 θ (w 和 b)和电池物理参数 φ (如欧姆内阻 R_0 、扩散系数 D_s 等),从而实现SOC与模型参数的在线联合估计。这种基于梯度优化的同步估计方法利用自动微分技术精确计算物理残差对模型参数的偏导数,通过共享参数优化框架确保状态估计和参数辨识的同步进行,避免了传统交替估计方法带来的误差累积问题。

联合估计机制通过自适应参数跟踪策略和多样

间尺度协同优化,有效应对电池老化等时变因素带来的挑战。自适应学习率机制使估计器能够在线跟踪参数变化,而多时间尺度优化策略则兼顾了SOC快速动态特性和模型参数缓慢变化特性。这种机制不仅保证了参数估计的物理一致性,还通过物理约束天然地提供了参数可辨识性的数学保障,当物理参数的变化显著影响系统输出时,梯度信号将驱动参数向真实值收敛,显著提升了电池管理系统的自适应能力和长期估计精度。

3 PINN用于SOC估计的对比分析与优势论证

3.1 确立对比分析框架

为系统论证PINN在电池SOC估计中的优越性,本节从估计精度、鲁棒性、模型泛化能力、计算效率与PINN适用性五个核心维度构建系统化的对比基准,旨在对各类SOC估计方法进行全面、客观的性能评估^[74]。估计精度反映算法输出与真实值的偏差程度,通常采用均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)等统计指标量化^[75-76];鲁棒性关注算法在模型失配、测量噪声等非理想条件下的适应能力^[77-78];模型泛化能力用于衡量方法在新工况、不同电池型号及全生命周期内的外推性能^[79];而计算效率则直接影响算法在资源受限的嵌入式BMS中的工程可行性,需从时间与空间复杂度两方面综合评估。上述维度共同构成有机联系的整体,为科学评估SOC估计方法提供了系统依据。

3.2 基于多维评估框架的交叉对比与批判性分析

为系统、公正地评估PINN相较于传统范式的性能,本节将依据3.1节建立的多维框架,对所汇总的代表性文献进行交叉对比分析如表2所示。需要特别指出的是,由于PINN在电池SOC估计领域仍处于快速发展阶段,其公开的高水平研究文献数量相对有限,且实验条件各异。因此,本节的分析将更侧重于揭示不同方法的内在特性、优势边界及其性能权衡的总体趋势,而非单纯追求数值上的直接排名。这种基于趋势的、批判性的视角,对于理解各类方法的适用场景并指引未来研究方向具有重要意义。

表 2 数据驱动、模型驱动、“数据-物理”融合、PINN 的文献对比

Table 2 Comparison of data driven methods, model driven methods, data-physical integration methods, and PINN methods in the literature					
文献	方法	方法类别	估计精度	测试条件	计算效率
[80]	EKF-AUKF 联合算法+带参考补偿的混合策略	模型驱动	RMSE: 1.18%~2.31% MaxAE: 2.8%~5.1%	温度: 25℃ 工况: BBDST 电池类型: LiFePO ₄ 电池 噪声: 电压误差(10~50 mV), 电流误差(30~100 mA)	单次估计时间: 约为0.139 ms 计算复杂度: 与 EKF-AUKF 相当, 为 $O(n^2)$
[81]	DMC-EKF	模型驱动	OCV 辨识 MAD: <10 mV SOC 估计 MAD: <5%	温度: 25℃ 工况: NEDC 电池类型: 3.6 V/100 Ah 锂离子电池	计算量小, 适合嵌入式系统在线运行
[82]	PINN (电池退化动力学 PDE; 损失函数包含数据拟合、物理方程约束和单调性约束)	PINN	MAPE: 0.85%~0.89%(跨数据集) RMSE: 1.31%~1.52% (小样本场景)	温度: 25℃ 工况: 恒流-恒压(CC-CV)充电、动态放电协议 电池类型: NCM、NCA、LFP 数据集: XJTU, TJU, HUST, MIT 四个大型公开数据集	计算复杂度: 与标准神经网络前向传播相当, 为 $O(n^2)$ 迁移效率: 通过冻结物理网络参数, 微调实现高效跨数据集适配
[83]	BLS+ AUKF+ BI	数据-模型融合	RMSE: <0.51% MAPE: <0.71% MaxAE: 2.0%~3.8% (在复杂噪声与变温条件下)	温度: 10℃, 25℃, 40℃ 工况: UDDS, US06 电池类型: 软包 NCM 锂离子电池 噪声: 高斯噪声($\sigma=0.05$)	离线训练时间: 约 0.42 s 在线单步估计时间: < 60 ms
[84]	BPINN (将 P-IC 与 SOH 的单调递减关系作为物理约束, 通过修改损失函数嵌入前馈神经网络(FNN)的训练过程)	PINN	MAE: < 0.4% RMSE: < 0.4%	温度: 24℃ 工况: CC-CV 充电, 多种动态放电协议 电池类型: NCA (NASA), NMC (NASA), LFP (牛津) 数据来源: NASA 电池数据集, 牛津大学电池数据集	结构轻量, 收敛快, 支持在线高效微调。PINNMAE: < 0.4% RMSE: < 0.4% 温度: 24℃ 工况: CC-CV 充电, 多种动态放电协议 电池类型: NCA (NASA), NMC (NASA), LFP (牛津) 数据来源: NASA 电池数据集, 牛津大学电池数据集 结构轻量, 收敛快, 支持在线高效微调
[85]	ASTRUKF	模型驱动	MaxAE: 10 ⁻⁸ (0℃) MaxAE: 10 ⁻¹² (15℃ & 25℃)	温度: 0℃, 15℃, 25℃ 工况: 脉冲放电实验 (0.1 C 倍率) 电池类型: EVE-LF280K 锂离子电池	算法复杂度低, 数值稳定性高
[86]	PINN (基于改进的 Verhulst 模型构建 PDE, 将健康指标(HI)和时间作为输入, 融合物理约束)	PINN	SOH 估计 RMSPE: 0.42%~0.49% RUL 预测 RMSE: 45.86~56.29 周期	工况: 多种快充协议下的循环老化数据 电池类型: LiFePO ₄ /石墨电池 数据集: 公共数据集 (3 个测试案例, Case A, B, C)	训练耗时可控, AdpBal 机制有效提升收敛稳定性与效率
[87]	CGC-PINN (计算模型输出对输入特征的偏导数, 并将其作为约束融入损失函数)	PINN	SOH 估计 MAPE: 0.75% S-DP 预测偏差: 约 0.01 RUL 预测 MAE: 104 周期	温度: 25℃, 35℃, 45℃ 工况: 多种充放电策略 电池类型: LFP, NCA 数据集: HUST 数据集, TJU 数据集	训练耗时可控, 推理效率高 (GPU: 0.069 ms)
[88]	BBN-aEKF	数据-模型融合	RMSE: 0.0031~0.0038 ME: <1.96%	温度: 0℃, 25℃, 40℃ 工况: ECE 和 UDDS 动态驾驶工况 电池类型: NCM 三元锂离子电池包	收敛时间在 10~20 s 内

续表					
文献	方法	方法类别	估计精度	测试条件	计算效率
[89]	Rint 模型+XGBoost	数据-模型融合	RMSE: <1% ME: 2% MAE: 约 0.57%	温度: 25℃ 工况: US06 (训练), UDDS, WLTP, Hybrid (测试) 电池类型: 磷酸铁锂 (LFP)	在线 SOC 估计速度小于 1 s
[90]	EKF-LSTM 混合增强算法	数据-模型融合	高斯噪声下 RMSE: 0.15% (DST 工况) 非高斯噪声下 RMSE: 0.2% ~0.5% ME: < 1%	温度: 25℃ 工况: DST, FUDS, US08, BJDST 电池类型: INR 18650-20R 锂离子电池	以离线训练成本换取在线估计的超高精度和强鲁棒性
[91]	DA-GRU	数据驱动	自有数据集: MAE: ≤0.5% RMSE: 约 0.4% Maryland 数据集: MAE: ≤0.6% RMSE: ≤1.5%	温度: 室温; 并在公共数据集上验证了 0℃, 25℃, 45℃ 下的性能。 工况: BJDST, FUDS, US06 电池类型: Panasonic NCR186 50PF 数据分割: 使用交叉验证	GRU 核心结构使其比同规模 LSTM 参数更少、训练更快, 在线推理效率与标准 RNN 相当, 满足实时性要求
[92]	CNN-BWGRU	数据驱动	0℃: MAE 约 0.0066, RMSE 约 0.0086 -10℃ & -20℃: MAE 约 0.0127, RMSE 约 0.0171	温度: 0℃, -10℃, -20℃ 工况: UDDS, US06, HWFET, LA92, 以及 8 种随机混合工况 电池类型: LG 18650 锂离子电池 数据划分: 使用 Mixed 1~8 数据训练, 使用 4 种标准工况数据测试, 验证泛化能力。	网络规模适中, 离线训练 1000 个周期后, 在线推理效率高且计算量固定满足 BMS 实时性要求
[93]	IBMO-SVM 混合模型	数据驱动	RMSE: 0.0042 MAPE: 0.61% R²: 0.9994	温度: 24℃ 电池类型: 商用 18650 三元锂离子电池 数据分割: 按 50%/50% 的比例随机划分为训练集和测试集	IBMO 的平均运行时间与 BMO 处于同一数量级, 未显著增加计算复杂度
[94]	DSA-RFR 混合模型	数据驱动	(HPPC 测试, 室温): RMSE: 0.382 MAE: 0.086% 动态工况性能: MAE: 0.193%(DST), 0.346%(FUDS)	温度: 0℃, 25℃, 45℃ 工况: HPPC、DST、FUDS 电池类型: LiNMC 锂离子电池 数据划分: 按 70%~30% 的比例进行训练集-测试集划分	训练过程为离线进行, 训练完成的 RFR 模型可用于 BMS 中的在线实时估计, 推理效率高

基于表 2 中高质量文献的系统分析, 可以从五个核心维度对 PINN 方法与物理驱动方法、数据驱动方法以及“数据-物理”融合方法进行深入对比分析。

3.2.1 模型估计精度对比

根据表 2 的结果, PINN 展现出的高精度, 其 RMSE 普遍低于 1.5%, 文献[80]的特定优化模型 BPINN 估计模型中可达<0.5%, 本质是其机理引导的精确性的体现, 这不仅能有效利用数据的拟合能力, 更关键的是能抵制产生物理不合理结果的过拟合, 从而在复杂多变工况下实现稳健的高精度。相比之下, 传统模型驱动方法(如文献[76]中的 EKF-AUKF 混合策略精度约 1.18%)的精度受限于其模型的结构简化。其精度是以模型复杂度和泛化能

力为代价, 换取计算效率的结果。数据驱动方法(如文献[87]中的 DA-GRU 在特定条件下 MAE≤0.5%)则展现出另一种权衡: 其在训练数据分布内可达到极高精度, 但这是一种脆弱的高精度, 高度依赖于数据质量和覆盖范围, 在分布外工况下易出现性能断崖式下跌。图 4 展示了四类方法在估计精度(RMSE)上的分布趋势, 从统计视角为上述分析提供了直观证据。数据驱动方法在箱线图中呈现巨大的离散性, 其下边缘较低表明在理想数据条件下可实现极高精度, 但广泛的上边缘与异常值也揭示了其性能对数据分布的本质依赖性。传统模型驱动方法的精度在当前对比中尚有提升空间。简单融合方法的整体精度分布最为集中且位置最低, 表明其在现有研究中实现了最优的稳定性和综合精

度。PINN方法的精度分布范围相对更广，其中位数与简单融合方法相当，但精度下限同样极低，表明其在特定条件下能达到与最佳方法媲美的顶尖性能；其一定的分布宽度也反映了其性能对网络实现与训练策略较为敏感，这恰恰凸显了其通过进一步优化以获得更高、更稳定精度的巨大潜力。




图4 四类方法估计精度分布趋势对比分析图

Fig. 4 Accuracy comparison analysis chart for four categories of methods

3.2.2 模型鲁棒性分析

传统模型驱动方法的鲁棒性框架建立在参数预设和局部线性化的基础之上，其在固定温度和标准噪声下的稳定性，源于算法在预设工况下的最优滤波性能。然而，一旦遭遇温度骤变等超越其预设模型线性化范围的扰动，其基于固定参数的模型将迅速失配，导致估计性能急剧衰。而数据-模型融合方法试图通过引入在线更新机制来突破上述局限，其增强的动态工况适应性代表了向动态鲁棒性的演进。然而，这种融合往往需要通过复杂的参数调整策略来实现，这本身又引入了新的脆弱性：调整策略的设计不当或其对噪声的敏感性，可能使整个系统陷入不稳定的正反馈循环。因此，该方法在提升鲁棒性的同时，也显著增加了系统的复杂性和不确定性。相比之下，PINN所展现出的强大温度适应性，如文献[83]在25℃、35℃、45℃等多温度点均保持高精度，根源在于其将物理规律本身作为应对扰动的稳定器。如离子扩散方程从物理上内在地描述了电池行为随温度变化的规律，PINN通过这些方程作为约束，使其预测结果天然地顺应了物理机理，从而对温度变化这类由物理规律主导的扰动表现出极强的适应性。

3.2.3 模型泛化能力评估

四类SOC估计方法的泛化能力存在显著差异。

PINN展现出卓越的泛化性能，通过将电化学反应方程作为嵌入网络的硬约束，PINN的预测在面对未训练工况时，能够通过物理原理而非数据插值进行合理推断，从而显著缓解了纯数据驱动的分外失效问题。相较之下，传统模型驱动方法的泛化能力源于其固化的机理框架，当新工况处于模型假设的边界内时，其能保持一定合理性；一旦触及模型边界，性能会断崖式下跌。数据驱动方法的泛化能力则完全依赖于数据覆盖的完备性，其在训练分布内可达到极高精度，但其“黑箱”特性导致其学习的是数据统计关联而非物理规律。当输入特征略微超出训练分布，其输出可能急剧偏离物理真实，甚至产生违背基本守恒律的预测结果。“数据-物理”简单融合方法虽然有所改进，其泛化性能优于纯数据驱动，但物理信息仅作为被动输入，而非主动约束，无法根本解决分布外预测结果的合理性问题。

3.2.4 计算效率的实用性分析

计算效率直接影响算法在资源受限的嵌入式BMS中的工程可行性。PINN在计算效率上呈现出显著的训练-推理二元性。其训练过程计算成本高昂，需要GPU加速且内存占用较大通常为150~450 KB，涉及复杂的反向传播和物理残差计算，导致超参数调优耗时较长。然而，一旦训练完成，其在线推理效率可接受，前向传播速度可满足实时性要求。因此，PINN的效率是以离线训练成本置换在线估计的卓越综合性能。相比之下，传统模型驱动方法在计算效率上绝对占优，文献[76]的EKF-AUKF联合算法单次估计仅需0.139 ms，极度适合实时嵌入式应用，然而其效率优势本质上是通过牺牲模型适应性和复杂度换取的，在面对复杂动态工况时，可能因模型失配而需频繁重新初始化或调参，反而增加整体运维成本。数据驱动方法的计算效率训练阶段需要大量数据和计算资源，但部署后推理效率较高，然而，其效率受模型复杂度显著影响，如文献[88]提出的CNN-BWGRU模型，虽然能够提升精度，但是内存占用和计算量急剧增加，可能超出嵌入式硬件限制。“数据-物理”简单融合方法在效率和精度之间取得了较好平衡，文献[85]所提出的SOC估计模型在线估计速度小于1 s，其效率提升源于结合了模型驱动的快速推理和数据驱动的自适应学习，但这种融合尚未实现机理与数据的深度耦合，估计效率有待进一步提升。

3.2.5 PINN适用性分析

从“性能表现-内在机理-应用边界”三个层面分析，对PINN在复杂工况下的适用性形成更系统的认识。首先在应对变温、噪声等环境扰动时，PINN因内嵌的物理方程为网络训练提供了正则化约束，有效抑制了由数据噪声引发的输出突变，这使其在跨数据集测试中仍能保持稳定的精度。如文献[78]中PINN的MAPE为0.85%，显著优于文献[76]中传统扩展卡尔曼滤波在单一噪声工况下1.18%的RMSE；同时，相较于纯数据驱动模型，其内嵌的物理先验知识有助于在训练数据未完全覆盖的扰动区间维持更平稳的泛化性能。其次，在动态变载与复杂工况下，PINN同样能够通过神经网络组件灵活补偿如一阶RC等效电路模型的未建模动态，同时其物理损失项确保了状态轨迹符合基本规律，避免了纯数据驱动方法可能产生的物理不合理输出。

然而，PINN的优势发挥存在明确边界，其性能根本上依赖于所嵌入物理方程在形式上的正确性，其本质是一种在近似正确物理指引下的数据驱动方法，若机理认知存在根本性错误，物理约束将

转化为系统性偏差。与文献[76]中的EKF-AUKF模型驱动方法相比，PINN牺牲了参数明确、计算高效的特性，增强了对模型失配与不确定性的适应能力；与文献[87]的DA-GRU等纯数据驱动方法相比，PINN则以更高的离线训练复杂度为代价，换取了更强的外推鲁棒性和物理可解释性。而如文献[79]所提出的轻量级融合方法，则在计算效率与精度之间进行了更侧重于工程实用的折中。因此，PINN并非全能解决方案，而是在机理相对明确、可接受高离线训练成本以换取高精度与强泛化能力的场景下的优选方案；在需快速在线部署、计算资源严格受限或物理模型本身高度不确定的场景中，其适用性则受到限制。

3.3 综合对比分析总结

基于前述对估计精度、鲁棒性、泛化能力、计算效率与PINN模型适用性五个维度的系统剖析，为更系统、直观地对比四类SOC估计方法的性能差异与内在权衡，对四类SOC估计方法从核心机理、量化性能、优势与局限三个层面进行结构化的梳理如表3所示。

表3 四类SOC估计方法横向对比
Table 3 Comparative analysis of four SOC estimation methods

对比维度	PINN	基于模型驱动	基于数据驱动	简单融合
核心机理	机理与数据深度融合	基于预设模型与滤波	完全依赖数据拟合	模型与数据松散结合
估计精度	潜力高，可达及高精度	受模型简化限制	在数据分布内拟合精度极高	在典型场景下精度高且稳定
模型鲁棒性	强（物理规律稳定）	弱（严重依赖模型参数的准确性与工况的预设匹配度）	弱（对训练数据分布外扰动敏感，行为不可预测）	良好（高度依赖于融合策略调整）
泛化能力	强（物理原理外推）	有限（模型边界内有效）	弱（“黑箱”，易失效）	中等（未深度融合，物理外推能力有限）
计算效率	离线成本极高，在线推理快	在线计算效率极高	训练成本高，推理快	在线计算复杂度增加，但低于PINN训练成本
主要优势	高精度、强泛化、物理一致	计算快、易部署、理论清晰	数据内拟合精度高、灵活	兼顾效率与自适应
关键局限	依赖准确物理模型，训练成本高	受限于模型精度，适应性差	需大量数据、“黑箱”特性、安全隐患	融合浅，性能提升有限

四类方法在“精度-鲁棒-泛化-效率”四维目标上呈现出根本性不同的权衡策略，表现为差异化的性能特征与内在权衡，四种电池状态估计方法综合性能对比趋势如图5雷达图所示，各种方法的性能趋势在雷达图中得到直观验证。

该图清晰地显示，PINN方法所覆盖的性能轮廓面积最大、形态最为饱满均衡，远优于其他三类方法。传统模型驱动方法的图形呈现出效率尖峰形态，凸显了其以牺牲泛化性与精度为代价换取极致实时

性的特点；数据驱动方法的轮廓则呈精度孤岛状，表明其在特定数据分布内表现优异但泛化性存在明显短板；数据-模型融合方法的轮廓虽表现均衡，但面积远小于PINN。PINN饱满的雷达图形态，强有力地证明了其通过物理信息融合，成功实现了在多个关键性能指标上的协同优化与最佳平衡。这标志着SOC估计技术的研究重心，正从传统的“牺牲与权衡”范式，转向追求综合性能最优的新范式，为构建下一代高可靠电池管理系统奠定了理论基础。




图5 四种电池状态估计方法综合性能对比趋势雷达图
Fig. 5 Trend radar chart comparing the comprehensive performance of four battery state estimation methods

4 展望与挑战

尽管PINN为电池SOC估计提供了机理与数据融合的新范式，然而，PINN在当前发展阶段仍面临诸多挑战。本部分将系统剖析面临的主要瓶颈，展望未来的重点研究方向，具体内容如图6所示。

PINN在电池SOC估计中的应用挑战主要源于其自身固有的训练难题和电池系统特有的复杂性。多目标损失函数中各项权重的平衡是首要难题，固定的权重策略难以适应电池动态工况^[95-96]。同时，训练过程常面临梯度不稳定问题，尤其在处理电化学模型中的刚性方程时，收敛困难或时间过长^[97]，导致训练时间延长甚至难以收敛。其次，PINN的

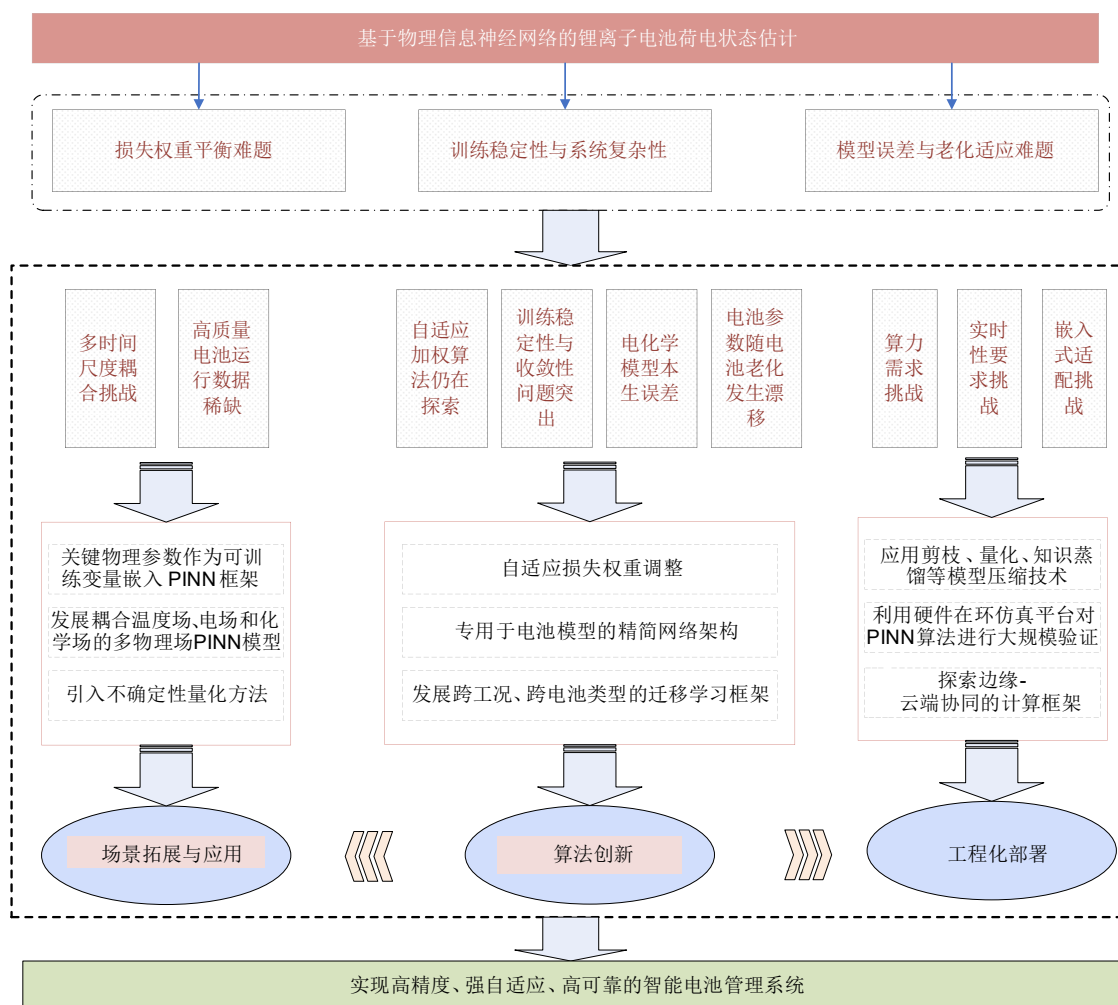


图6 PINN-SOC估计的挑战与展望
Fig. 6 Challenges and prospects for PINN-SOC estimation

性能依赖于嵌入的物理模型精度,简化电化学模型本身存在的误差会作为系统偏差被引入学习过程^[98-99]。电池内部涉及秒级到小时级的多种动力学过程,标准PINN架构在处理这种复杂的多时间尺度动态特性时面临困难。电池管理系统对算法的计算效率通常需要毫秒级响应^[100],然而PINN相对复杂的网络结构和前向传播计算量,使其在资源受限的嵌入式硬件上的实时运行面临挑战。此外,高质量的电池运行数据往往稀缺且分布不均^[101],特别是在极端工况下数据获取困难。

为应对上述挑战,未来研究可从算法创新、应用拓展和工程化部署三个层面协同推进。①在算法层面创新上,发展自适应损失权重调整策略和多时间尺度PINN架构^[102],以应对动态工况与内部耦合过程。设计精简网络,如利用注意力机制聚焦关键状态变量^[103]并探索迁移学习框架^[104-105],提升模型的效率与泛化能力。②在应用层面拓展上,探索将关键物理参数作为可训练变量嵌入PINN框架^[106],发展多物理场耦合模型^[107]以提升全气候鲁棒性。在PINN框架中引入不确定性量化方法^[108],为BMS决策提供置信区间,并探索零样本学习在新工况下的推理潜力。③在部署层面优化上,为应对电池管理系统面临算力需求、实时性要求与嵌入式适配的三大瓶颈,需采用网络剪枝、参数量化、知识蒸馏^[109]等技术来压缩模型、提升效率,并利用硬件在环仿真平台^[100]进行可靠性验证,远期可探索边缘-云端协同计算框架,在云端完成复杂训练,在车端部署轻量化模型,以实现高可靠、自适应的电池状态智能管控。

5 总 结

本文系统综述了PINN在锂离子电池SOC估计中的应用,通过理论分析、架构设计和性能验证,建立了完整的PINN-SOC估计研究框架。研究表明,PINN通过将电化学机理模型与深度学习相融合,致力于实现物理规律约束与数据驱动学习的有机统一,不仅在估计精度(RMSE 0.5%~2.0%)上显示出较好潜力,同时在泛化能力(性能保持率75%~92%)和鲁棒性上也展现出一定的优势。其物理约束嵌入机制有助于缓解纯数据驱动方法的过拟合问题,而状态与参数联合估计能力则为解决传

统方法中状态估计与参数辨识相互耦合的难题提供了可能途径。然而,PINN在实际应用中仍存在计算效率、训练稳定性和工程化部署等方面的挑战。未来研究可重点关注自适应训练算法、轻量化网络结构和多物理场耦合建模等方向,通过算法创新和硬件加速技术探索瓶颈突破。随着相关技术的不断发展,PINN有潜力为下一代智能电池管理系统提供技术参考,助力电池状态估计从经验模型向机理与数据深度融合的新范式转变,为电池安全管理贡献新可能。

参 考 文 献

- [1] XU J J, CAI X Y, CAI S M, et al. High-energy lithium-ion batteries: Recent progress and a promising future in applications[J]. *Energy & Environmental Materials*, 2023, 6(5): e12450. DOI: 10.1002/eeem2.12450.
- [2] GAO Y L, PAN Z H, SUN J G, et al. High-energy batteries: Beyond lithium-ion and their long road to commercialisation[J]. *Nano-Micro Letters*, 2022, 14(1): 94. DOI: 10.1007/s40820-022-00844-2.
- [3] 雷亦鸣. 基于数据驱动的稳健SOC估计融合方法研究[D]. 西安: 西安理工大学, 2024.
LEI Y M. Research on robust soc estimation fusion method based on data-driven approach[D]. Xi'an: Xi'an University of Technology, 2024.
- [4] SHI H T, WU Q Q, WANG S L, et al. Improved back-propagation neural network-multi-information gain optimization Kalman filter method for high-precision estimation of state-of-energy in lithium-ion batteries[J]. *Energy*, 2025, 335: 138214. DOI: 10.1016/j.energy.2025.138214.
- [5] 步传宇, 姜昆, 任军, 等. 基于改进型ASRCKF算法的锂离子电池荷电状态估计[J]. *广东电力*, 2020, 33(10): 16-25. DOI: 10.3969/j.issn.1007-290X.2020.010.003.
BU C Y, JIANG K, REN J, et al. Estimation of SOC of lithium-ion battery based on improved ASRCKF[J]. *Guangdong Electric Power*, 2020, 33(10): 16-25. DOI: 10.3969/j.issn.1007-290X.2020.010.003.
- [6] LI J W, CHE Y H, ZHANG K, et al. Efficient battery fault monitoring in electric vehicles: Advancing from detection to quantification[J]. *Energy*, 2024, 313: 134150. DOI: 10.1016/j.energy.2024.134150.
- [7] XIE J M, WEI X Y, BO X Q, et al. State of charge estimation of lithium-ion battery based on extended Kalman filter algorithm[J]. *Frontiers in Energy Research*, 2023, 11: 1180881. DOI: 10.3389/ferg.2023.1180881.
- [8] LIU Q H, YU Q Q. The lithium battery SOC estimation on square root unscented Kalman filter[J]. *Energy Reports*, 2022, 8: 286-294. DOI: 10.1016/j.egyr.2022.05.079.
- [9] WU W B, ZENG J B, JIAN Q F, et al. A Li-ion battery state of

- charge estimation strategy based on the suboptimal multiple fading factor extended Kalman filter algorithm[J]. *Processes*, 2024, 12(5): DOI:10.3390/pr12050998.
- [10] SOLOMON O O, ZHENG W, CHEN J X, et al. State of charge estimation of lithium-ion battery using an improved fractional-order extended Kalman filter[J]. *Journal of Energy Storage*, 2022, 49: 104007. DOI:10.1016/j.est.2022.104007.
- [11] ZHANG M, YANG D F, DU J X, et al. A review of SOH prediction of Li-ion batteries based on data-driven algorithms[J]. *Energies*, 2023, 16(7): 1-28.
- [12] LIU P, WANG L Z, RANJAN R, et al. A survey on active deep learning: From model driven to data driven[J]. *ACM Computing Surveys*, 2022, 54(10s): 1-34. DOI:10.1145/3510414.
- [13] XUE P C, QIU R, PENG C C, et al. Solutions for lithium battery materials data issues in machine learning: Overview and future outlook[J]. *Advanced Science*, 2024, 11(48): 2410065. DOI: 10.1002/adv.202410065.
- [14] 于程程. 基于数据驱动的锂电池状态及剩余充电时间估计方法研究[D]. 烟台: 烟台大学, 2024.
- YU C C. Research on state and remaining charge time estimation of lithium battery based on data-driven[D]. Yantai: Yantai University, 2024.
- [15] BASIT S, UYAR M. Data-driven prediction of copper leaching yield from brass waste using stacking ensemble learning[J]. *Separation and Purification Technology*, 2025, 378: 134691. DOI: 10.1016/j.seppur.2025.134691.
- [16] ZHOU Q Q, TENG S, SITU Z X, et al. A deep-learning-technique-based data-driven model for accurate and rapid flood predictions in temporal and spatial dimensions[J]. *Hydrology and Earth System Sciences*, 2023, 27(9): 1791-1808. DOI:10.5194/hess-27-1791-2023.
- [17] WAHEED W, XU Q S. Data-driven short term load forecasting with deep neural networks: Unlocking insights for sustainable energy management[J]. *Electric Power Systems Research*, 2024, 232: 110376. DOI:10.1016/j.epsr.2024.110376.
- [18] SHI D P, ZHAO J Y, WANG Z H, et al. Spatial-temporal self-attention transformer networks for battery state of charge estimation[J]. *Electronics*, 2023, 12(12): DOI: 10.3390/electronics12122598.
- [19] ZHANG Z P, FAN Y, TIAN J Q, et al. Online estimation of model parameters and state of charge for lithium-ion battery using multitimescale recurrent neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2025, 72(8): 8119-8129. DOI: 10.1109/TIE.2025.3528505.
- [20] WANG Y X, CHEN Z H, ZHANG W. Lithium-ion battery state-of-charge estimation for small target sample sets using the improved GRU-based transfer learning[J]. *Energy*, 2022, 244: 123178. DOI:10.1016/j.energy.2022.123178.
- [21] SHEN L, SUN Y, YU Z Y, et al. On efficient training of large-scale deep learning models[J]. *ACM Computing Surveys*, 2025, 57(3): 1-36. DOI:10.1145/3700439.
- [22] WEN H, KHAN F, AMIN M T, et al. Myths and misconceptions of data-driven methods: Applications to process safety analysis[J]. *Computers & Chemical Engineering*, 2022, 158: 107639. DOI: 10.1016/j.compchemeng.2021.107639.
- [23] 肖张华. 结合机理信息与数据驱动的锂离子电池荷电状态估计方法研究[D]. 北京: 北京化工大学, 2025.
- XIAO Z H. Hybrid mechanism-data-driven approach for state of charge estimation in lithium-ion batteries[D]. Beijing: Beijing University of Chemical Technology, 2025.
- [24] AHN J, LEE Y, HAN B, et al. A highly effective and robust structure-based LSTM with feature-vector tuning framework for high-accuracy SOC estimation in EV[J]. *Energy*, 2025, 325: 136134. DOI:10.1016/j.energy.2025.136134.
- [25] TAKYI-ANINAKWA P, WANG S L, LIU G C, et al. Enhanced extended-input LSTM with an adaptive singular value decomposition UKF for LIB SOC estimation using full-cycle current rate and temperature data[J]. *Applied Energy*, 2024, 363: 123056. DOI:10.1016/j.apenergy.2024.123056.
- [26] LUO K, ZHAO J S, WANG Y P, et al. Physics-informed neural networks for PDE problems: A comprehensive review[J]. *Artificial Intelligence Review*, 2025, 58(10): 323. DOI:10.1007/s10462-025-11322-7.
- [27] FALAS S, ASPROU M, KONSTANTINOUC, et al. Robust power system state estimation using physics-informed neural networks [J]. *IEEE Transactions on Industrial Informatics*, 2025, 21(10): 8057-8067. DOI:10.1109/TII.2025.3582293.
- [28] NASCIMENTO R G, VIANA F A C, CORBETTA M, et al. A framework for Li-ion battery prognosis based on hybrid Bayesian physics-informed neural networks[J]. *Scientific Reports*, 2023, 13: 13856. DOI:10.1038/s41598-023-33018-0.
- [29] WANG Y N, HAN X B, GUO D X, et al. Physics-informed recurrent neural network with fractional-order gradients for state-of-charge estimation of lithium-ion battery[J]. *IEEE Journal of Radio Frequency Identification*, 2022, 6: 968-971. DOI: 10.1109/JRFID.2022.3211841.
- [30] LAVAL Z K, YASSIN H, LAI D T C, et al. Physics-informed neural network (PINN) evolution and beyond: A systematic literature review and bibliometric analysis[J]. *Big Data and Cognitive Computing*, 2022, 6(4): DOI:10.3390/bdcc6040140.
- [31] PAN R B, XIAO F, SHEN M Y. Ro-PINN: A reduced order physics-informed neural network for solving the macroscopic model of pedestrian flows[J]. *Transportation Research Part C: Emerging Technologies*, 2024, 163: 104658. DOI:10.1016/j.trc.2024.104658.
- [32] XU L, YANG C H, XU X D, et al. Physics-informed stochastic configuration network promoted model predictive control with multi-objective optimization[J]. *Artificial Intelligence Review*, 2025, 58(9): 281. DOI:10.1007/s10462-025-11278-8.
- [33] WANG J F, JIA Y K, YANG N, et al. Precise equivalent circuit model for Li-ion battery by experimental improvement and parameter optimization[J]. *Journal of Energy Storage*, 2022, 52: 104980. DOI:10.1016/j.est.2022.104980.
- [34] BARZACCHI L, LAGNONI M, DI RIENZO R, et al. Enabling early detection of lithium-ion battery degradation by linking

- electrochemical properties to equivalent circuit model parameters [J]. *Journal of Energy Storage*, 2022, 50: 104213. DOI:10.1016/j.est.2022.104213.
- [35] MAHESHWARI A, NAGESWARI S. Real-time state of charge estimation for electric vehicle power batteries using optimized filter[J]. *Energy*, 2022, 254: 124328. DOI: 10.1016/j.energy.2022.124328.
- [36] VENNAM G, SAHOO A. A dynamic SOH-coupled lithium-ion cell model for state and parameter estimation[J]. *IEEE Transactions on Energy Conversion*, 2023, 38(2): 1186-1196. DOI: 10.1109/TEC.2022.3218344.
- [37] LIU F, SHAO C, SU W X, et al. Online joint estimator of key states for battery based on a new equivalent circuit model[J]. *Journal of Energy Storage*, 2022, 52: 104780. DOI: 10.1016/j.est.2022.104780.
- [38] BEDWAL K, MOULIK B, VANDANA. Novel equivalent circuit battery model with adaptive parameters for hybrid state of charge estimation[J]. *Journal of Energy Storage*, 2025, 137: 118653. DOI:10.1016/j.est.2025.118653.
- [39] LIU Y S, WANG L C, LI D Z, et al. State-of-health estimation of lithium-ion batteries based on electrochemical impedance spectroscopy: A review[J]. *Protection and Control of Modern Power Systems*, 2023, 8(1): 41. DOI: 10.1186/s41601-023-00314-w.
- [40] MIRANDA D, GONÇALVES R, WUTTKE S, et al. Overview on theoretical simulations of lithium-ion batteries and their application to battery separators[J]. *Advanced Energy Materials*, 2023, 13(13): 2203874. DOI:10.1002/aenm.202203874.
- [41] 张艳岗, 董泽庆, 郑利锋, 等. 锂离子动力电池电化学建模进展及降阶方法研究[J]. *物理学报*, 2025, 74(14): 375-390. DOI:10.7498/aps.74.20250591.
- ZHANG Y G, DONG Z Q, ZHENG L F, et al. Research on electrochemical modeling and order reduction methods for lithium-ion power batteries[J]. *Acta Physica Sinica*, 2025, 74(14): 375-390. DOI:10.7498/aps.74.20250591.
- [42] 郝天运. 基于数据融合的锂电池荷电状态估计[D]. 南京: 南京邮电大学, 2023.
- HAO T Y. SOE estimation for lithium-ion batteries based on data fusion [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2023.
- [43] WANG J R, MENG J H, PENG Q, et al. Lithium-ion battery state-of-charge estimation using electrochemical model with sensitive parameters adjustment[J]. *Batteries*, 2023, 9(3): DOI: 10.3390/batteries9030180.
- [44] ZHU G R, WU Z X, REN X T, et al. A self-correction single particle model of lithium-ion battery based on multi-population genetic algorithm[J]. *Journal of Energy Storage*, 2023, 71: 108005. DOI:10.1016/j.est.2023.108005.
- [45] TIAN A N, HE L Y, DONG K L, et al. An extended single-particle model based on physics-informed neural network for SOC state estimation of lithium-ion batteries[C]//Clean Energy Technology and Energy Storage Systems. Singapore: Springer, 2025: 300-316. DOI:10.1007/978-981-96-0232-2_24.
- [46] XIE J L, YU J H, LIU L Q, et al. Estimating the charge and temperature states for Li-ion batteries by coupling single particle kinetics and electrothermal effects[J]. *IEEE/ASME Transactions on Mechatronics*, 2025, 30(6): 4837-4848. DOI: 10.1109/TMECH.2025.3561894.
- [47] SHUI Z Y, LI X H, FENG Y, et al. Combining reduced-order model with data-driven model for parameter estimation of lithium-ion battery[J]. *IEEE Transactions on Industrial Electronics*, 2023, 70 (2): 1521-1531. DOI:10.1109/TIE.2022.3157980.
- [48] ZHOU B R, MENG C W, PANG T W, et al. A reduced-order method for battery modeling considering time-varying characteristics of the system[C]//2025 American Control Conference (ACC). July 8-10, 2025, Denver, CO, USA. IEEE, 2025: 2793-2798. DOI:10.23919/ACC63710.2025.11107672.
- [49] CUI Z H, WANG L C, LI Q, et al. A comprehensive review on the state of charge estimation for lithium-ion battery based on neural network[J]. *International Journal of Energy Research*, 2022, 46 (5): 5423-5440. DOI:10.1002/er.7545.
- [50] SHRIVASTAVA P, NAIDU P A, SHARMA S, et al. Review on technological advancement of lithium-ion battery states estimation methods for electric vehicle applications[J]. *Journal of Energy Storage*, 2023, 64: 107159. DOI: 10.1016/j.est.2023.107159.
- [51] HE L Y, TIAN A N, DING T, et al. Lithium-ion battery state estimation based on adaptive physics-informed neural network of electrochemical model[J]. *Measurement*, 2026, 257: 118985. DOI: 10.1016/j.measurement.2025.118985.
- [52] 闫洪迪, 崔承刚, 陈辉, 等. 基于融合物理模型与数据驱动模型的电池 SOH 估计方法 [J]. *电源技术*, 2025, 49(6): 1183-1191. DOI: 10.3969/j.issn.1002-087X.2025.06.013.
- YAN H D, CUI C G, CHEN H, et al. Battery SOH estimation method based on fusion of physical model and data-driven model[J]. *Chinese Journal of Power Sources*, 2025, 49(6): 1183-1191. DOI: 10.3969/j.issn.1002-087X.2025.06.013.
- [53] SAHU S, ACHARYA S, DUTT R, et al. NeuroECM: A physics-informed neural network fusion model for equivalent circuit model of Li-ion battery[C]//2025 23rd IEEE Interregional NEWCAS Conference (NEWCAS). June 22-25, 2025, Paris, France. IEEE, 2025: 626-630. DOI:10.1109/NewCAS64648.2025.11106964.
- [54] P A, R S V, CEPHAS I. Physics informed neural networks for reliable SOC estimation in lithium-ion battery management[C]//2024 9th International Conference on Communication and Electronics Systems (ICCES). December 16-18, 2024, Coimbatore, India. IEEE, 2025: 41-47. DOI: 10.1109/ICCES63552.2024.10860002.
- [55] KAJIURA Y, ESPIN J, ZHANG D. Physics-informed neural networks for discovering systems with unmeasurable states with application to lithium-ion batteries[C]//2024 American Control Conference (ACC). July 10-12, 2024, Toronto, ON, Canada. IEEE, 2024: 1959-1964. DOI:10.23919/ACC60939.2024.10644822.
- [56] WANG F J, ZHI Q Q, ZHAO Z B, et al. Inherently interpretable physics-informed neural network for battery modeling and

- prognosis[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(1): 1145-1159. DOI: 10.1109/TNNLS.2023.3329368.
- [57] CHEN L, CHANG C, LIU X Y, et al. Physics-informed neural networks for small sample state of health estimation of lithium-ion batteries[J]. Journal of Energy Storage, 2025, 122: 116559. DOI: 10.1016/j.est.2025.116559.
- [58] DANG L J, YANG J J, LIU M Q, et al. Differential equation-informed neural networks for state-of-charge estimation[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1000315. DOI:10.1109/TIM.2023.3334377.
- [59] GUO R H, HU C G, SHEN W X. An adaptive approach for battery state of charge and state of power co-estimation with a fractional-order multi-model system considering temperatures[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(12): 15131-15145. DOI:10.1109/TITS.2023.3299270.
- [60] LIU E H, WANG X, NIU G X, et al. Uncertainty management in lebesgue-sampling-based Li-ion battery SFP model for SOC estimation and RDT prediction[J]. IEEE/ASME Transactions on Mechatronics, 2023, 28(2): 611-620. DOI: 10.1109/TMECH.2022.3205244.
- [61] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686-707. DOI:10.1016/j.jcp.2018.10.045.
- [62] YANG X Y, DU Y X, LI L H, et al. Physics-informed neural network for model prediction and dynamics parameter identification of collaborative robot joints[J]. IEEE Robotics and Automation Letters, 2023, 8(12): 8462-8469. DOI: 10.1109/LRA.2023.3329620.
- [63] CHEN S Q, ZHANG Q, WANG D F, et al. Physics-informed neural networks for degradation diagnosis of lithium-ion batteries via electrochemical impedance spectroscopy[J]. Journal of Energy Storage, 2025, 140: 119127. DOI: 10.1016/j.est.2025.119127.
- [64] ZHOU K Q, QIN Y, YUEN C. Graph neural network-based lithium-ion battery state of health estimation using partial discharging curve[J]. Journal of Energy Storage, 2024, 100: 113502. DOI: 10.1016/j.est.2024.113502.
- [65] SCHREIBER C O, YOON H S, SHAH K. Understanding pitfalls and opportunities in estimating parameters of a physics-based battery model using a machine learning based method—a case study with long short-term memory neural network[J]. Journal of Electrochemical Energy Conversion and Storage, 2026, 23(2): 021103. DOI:10.1115/1.4069910.
- [66] TAO J J, WANG S L, CAO W, et al. A comprehensive review of multiple physical and data-driven model fusion methods for accurate lithium-ion battery inner state factor estimation[J]. Batteries, 2024, 10(12): 1-25.
- [67] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning[J]. Nature Reviews Physics, 2021, 3(6): 422-440. DOI:10.1038/s42254-021-00314-5.
- [68] JI C, DAI J D, ZHAI C, et al. A review on lithium-ion battery modeling from mechanism-based and data-driven perspectives [J]. Processes, 2024, 12(9): DOI:10.3390/pr12091871.
- [69] ALI H A, RAIJMAKERS L H J, TEMPEL H, et al. A hybrid electrochemical multi-particle model for Li-ion batteries[J]. Journal of the Electrochemical Society, 2024, 171(11): 110523. DOI:10.1149/1945-7111/ad92dd.
- [70] EL-DALAHMEH M. Physics modelling and adaptive signal processing filter for online condition monitoring and remaining useful life prediction of lithium-ion battery[D]. Middlesbrough: Teesside University, 2023.
- [71] HUANG Q, WANG S L, CHEN Z H, et al. Electrochemical modeling of energy storage lithium-ion battery[M]//Long-Term Health State Estimation of Energy Storage Lithium-Ion Battery Packs. Singapore: Springer Nature Singapore, 2023: 21-40. DOI: 10.1007/978-981-99-5344-8_2.
- [72] JAYASINGHE A E, FERNANDO N, KUMARAWADU S, et al. Review on Li-ion battery parameter extraction methods[J]. IEEE Access, 2023, 11: 73180-73197. DOI: 10.1109/ACCESS.2023.3296440.
- [73] 童剑城, 范斌, 林至诚, 等. 基于增广拉格朗日法的动态平衡物理信息神经网络[J]. 计算机工程与应用, 2025, 61(20): 170-181.
- TONG J C, FAN B, LIN Z C, et al. Dynamic balanced physics-informed neural network based on augmented Lagrange method [J]. Computer Engineering and Applications, 2025, 61(20): 170-181.
- [74] ADAIKKAPPAN M, SATHIYAMOORTHY N. Modeling, state of charge estimation, and charging of lithium-ion battery in electric vehicle: A review[J]. International Journal of Energy Research, 2022, 46(3): 2141-2165. DOI:10.1002/er.7339.
- [75] D O P, BABU P S, V I, et al. Enhanced SOC estimation of lithium ion batteries with RealTime data using machine learning algorithms[J]. Scientific Reports, 2024, 14: 16036. DOI: 10.1038/s41598-024-66997-9.
- [76] BEHNAMGOL V, ASADI M, MOHAMED M A A, et al. Comprehensive review of lithium-ion battery state of charge estimation by sliding mode observers[J]. Energies, 2024, 17(22): DOI:10.3390/en17225754.
- [77] KHAN A, NAQVI I H, HASSAN N U. A comprehensive analysis of battery EV (BEV) performance under conflicting metrics through strategic state of charge management[J]. IEEE Transactions on Transportation Electrification, 2025, 11(4): 9613-9629. DOI: 10.1109/TTE.2025.3562088.
- [78] VIEIRA R, KOLLMEYER P, PITAUT L, et al. Comprehensive comparison of machine learning and Kalman filter battery state of charge estimators[J]. IEEE Access, 2025, 13: 36321-36338. DOI: 10.1109/ACCESS.2025.3545380.
- [79] LIU Y F, HE Y J, BIAN H D, et al. A review of lithium-ion battery state of charge estimation based on deep learning: Directions for improvement and future trends[J]. Journal of Energy Storage, 2022, 52: 104664. DOI:10.1016/j.est.2022.104664.

- [80] WANG L X, DUAN J D, ZHAO K, et al. Online state of charge estimation of LiFePO_4 battery based on EKF-AUKF algorithm with reference compensation for estimation results[J]. *Journal of Energy Storage*, 2024, 100: 113504. DOI: 10.1016/j.est.2024.113504.
- [81] WANG Y Q, CHENG Y, XIONG Y, et al. Estimation of battery open-circuit voltage and state of charge based on dynamic matrix control-extended Kalman filter algorithm[J]. *Journal of Energy Storage*, 2022, 52: 104860. DOI:10.1016/j.est.2022.104860.
- [82] 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.
- [83] XU K K, HE T L, YANG P, et al. A new online SOC estimation method using broad learning system and adaptive unscented Kalman filter algorithm[J]. *Energy*, 2024, 309: 132920. DOI: 10.1016/j.energy.2024.132920.
- [84] SUN G Q, LIU Y F, LIU X W. A method for estimating lithium-ion battery state of health based on physics-informed machine learning[J]. *Journal of Power Sources*, 2025, 627: 235767. DOI: 10.1016/j.jpowsour.2024.235767.
- [85] ZHOU Z H, ZHAN M J, WU B G, et al. A novel adaptive unscented Kalman filter algorithm for SOC estimation to reduce the sensitivity of attenuation coefficient[J]. *Energy*, 2024, 307: 132598. DOI:10.1016/j.energy.2024.132598.
- [86] WEN P F, YE Z S, LI Y, et al. Physics-informed neural networks for prognostics and health management of lithium-ion batteries [J]. *IEEE Transactions on Intelligent Vehicles*, 2024, 9(1): 2276-2289. DOI:10.1109/TIV.2023.3315548.
- [87] YANG L, HE M J, REN Y T, et al. Physics-informed neural network for co-estimation of state of health, remaining useful life, and short-term degradation path in lithium-ion batteries[J]. *Applied Energy*, 2025, 398: 126427. DOI: 10.1016/j.apenergy.2025.126427.
- [88] SHI Q, JIANG Z X, WANG Z, et al. State of charge estimation by joint approach with model-based and data-driven algorithm for lithium-ion battery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3000610. DOI:10.1109/TIM.2022.3199253.
- [89] HOU J Y, XU J, LIN C P, et al. State of charge estimation for lithium-ion batteries based on battery model and data-driven fusion method[J]. *Energy*, 2024, 290: 130056. DOI: 10.1016/j.energy.2023.130056.
- [90] YU B J, WANG G, ZHU E N, et al. Predicting lithium-ion battery state of charge with long short-term memory network enhanced extended Kalman filter[J]. *Journal of Energy Storage*, 2025, 132: 117849. DOI:10.1016/j.est.2025.117849.
- [91] YANG K, TANG Y G, ZHANG S J, et al. A deep learning approach to state of charge estimation of lithium-ion batteries based on dual-stage attention mechanism[J]. *Energy*, 2022, 244: 123233. DOI:10.1016/j.energy.2022.123233.
- [92] CUI Z H, KANG L, LI L W, et al. A hybrid neural network model with improved input for state of charge estimation of lithium-ion battery at low temperatures[J]. *Renewable Energy*, 2022, 198: 1328-1340. DOI:10.1016/j.renene.2022.08.123.
- [93] LIU B Y, WANG H Y, TSENG M L, et al. State of charge estimation for lithium-ion batteries based on improved barnacle mating optimizer and support vector machine[J]. *Journal of Energy Storage*, 2022, 55: 105830. DOI:10.1016/j.est.2022.105830.
- [94] HOSSAIN LIPU M S, HANNAN M A, HUSSAIN A, et al. Real-time state of charge estimation of lithium-ion batteries using optimized random forest regression algorithm[J]. *IEEE Transactions on Intelligent Vehicles*, 2023, 8(1): 639-648. DOI: 10.1109/TIV.2022.3161301.
- [95] PSAROS A F, KAWAGUCHI K, KARNIADAKIS G E. Meta-learning PINN loss functions[J]. *Journal of Computational Physics*, 2022, 458: 111121. DOI:10.1016/j.jcp.2022.111121.
- [96] JI W Q, QIU W L, SHI Z Y, et al. Stiff-PINN: Physics-informed neural network for stiff chemical kinetics[J]. *The Journal of Physical Chemistry A*, 2021, 125(36): 8098-8106. DOI: 10.1021/acs.jpca.1c05102.
- [97] ZHANG S H, ZHANG C, WANG B S. CRK-PINN: A physics-informed neural network for solving combustion reaction kinetics ordinary differential equations[J]. *Combustion and Flame*, 2024, 269: 113647. DOI:10.1016/j.combustflame.2024.113647.
- [98] LI K Q, YIN Z Y, ZHANG N, et al. A PINN-based modelling approach for hydromechanical behaviour of unsaturated expansive soils[J]. *Computers and Geotechnics*, 2024, 169: 106174. DOI:10.1016/j.compgeo.2024.106174.
- [99] FU H J, LIU Z G, CUI K X, et al. Physics-informed neural network for spacecraft lithium-ion battery modeling and health diagnosis [J]. *IEEE/ASME Transactions on Mechatronics*, 2024, 29(5): 3546-3555. DOI:10.1109/TMECH.2023.3348519.
- [100] SU C, LIANG J W, HE Z S. E-PINN: A fast physics-informed neural network based on explicit time-domain method for dynamic response prediction of nonlinear structures[J]. *Engineering Structures*, 2024, 321: 118900. DOI: 10.1016/j.engstruct.2024.118900.
- [101] WANG C, XIAO Q Q, ZHOU Z K, et al. A data-assisted physics-informed neural network (DA-PINN) for fretting fatigue lifetime prediction[J]. *International Journal of Mechanical System Dynamics*, 2024, 4(3): 361-373. DOI:10.1002/msd2.12127.
- [102] MENG X H, LI Z, ZHANG D K, et al. PPINN: Parareal physics-informed neural network for time-dependent PDEs[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 370: 113250. DOI:10.1016/j.cma.2020.113250.
- [103] WANG Y F, ZHONG L L. NAS-PINN: Neural architecture search-guided physics-informed neural network for solving PDEs [J]. *Journal of Computational Physics*, 2024, 496: 112603. DOI: 10.1016/j.jcp.2023.112603.
- [104] LIU Y, LIU W, YAN X S, et al. Adaptive transfer learning for PINN[J]. *Journal of Computational Physics*, 2023, 490: 112291. DOI:10.1016/j.jcp.2023.112291.
- [105] PRANTIKOS K, CHATZIDAKIS S, TSOUKALAS L H, et al. Physics-informed neural network with transfer learning (TL-PINN)

- based on domain similarity measure for prediction of nuclear reactor transients[J]. Scientific Reports, 2023, 13: 16840. DOI: 10.1038/s41598-023-43325-1.
- [106] YANG X Y, ZHOU Z X, LI L H, et al. Collaborative robot dynamics with physical human-robot interaction and parameter identification with PINN[J]. Mechanism and Machine Theory, 2023, 189: 105439. DOI:10.1016/j.mechmachtheory.2023.105439.
- [107] NILPUENG K, KASEETHONG P, MESGARPOUR M, et al. A novel temperature prediction method without using energy equation based on physics-informed neural network (PINN): A case study on plate- circular/square pin-fin heat sinks[J]. Engineering Analysis with Boundary Elements, 2022, 145: 404-417. DOI:10.1016/j.enganabound.2022.09.032.
- [108] MENG Z, QIAN Q C, XU M Q, et al. PINN-FORM: A new physics-informed neural network for reliability analysis with partial differential equation[J]. Computer Methods in Applied Mechanics and Engineering, 2023, 414: 116172. DOI: 10.1016/j.cma. 2023. 116172.
- [109] CHIU P H, WONG J C, OOI C, et al. CAN-PINN: A fast physics-informed neural network based on coupled-automatic-numerical differentiation method[J]. Computer Methods in Applied Mechanics and Engineering, 2022, 395: 114909. DOI:10.1016/j.cma.2022.114909.