
基于数字孪生的电化学储能系统可靠性评估
关键技术研发（省重配套）研究技术报告

中国科学院深圳先进技术研究院

二〇二五年六月

目 录

一、项目的研究背景及意义.....	1
1.1 项目研究背景.....	1
1.2 项目研究意义.....	3
1.3 国内外研究现状.....	4
二、主要研究内容.....	10
2.2 任务 1 基于数字孪生的储能系统典型故障仿真模块研究.....	10
2.2.1 概述.....	10
2.2.2 基于电池特征与故障响应耦合的储能系统多参量故障模拟验证模块.....	11
2.2.3 搭建机理模型和数学模型融合驱动的储能系统故障模型.....	17
2.2.4 PCS 数字孪生建模方法研究	20
2.3 任务 2：基于数字孪生的储能系统可靠性评估模块研究.....	36
2.3.1 融合深度学习与迁移学习的电池退化模式量化框架.....	36
2.3.2 基于多维通用生成函数的储能电池可靠性评估.....	44
2.4 任务 3：基于数字孪生的储能系统全生命周期监测平台研发.....	55
2.4.1 概述.....	55
2.4.2 搭建模型-数据双驱动的电化学储能系统可靠性数字孪生分析平台 ..	55
2.5 任务 4：储能系统多源异构信息与数字孪生系统集成.....	63
2.5.1 概述.....	63
2.5.2 储能系统多组件一体化建模方法研究.....	64
2.5.3 储能系统多源异构信息融合方法研究.....	64
2.5.4 储能数字孪生系统计算推演方法研究.....	65
2.6 任务 5：面向不同应用场景的储能系统可靠性评估.....	66
2.6.1 概述.....	66
2.6.2 典型供电场景工况研究.....	66
2.6.3 基于典型供电场景的电池容量与功率模型.....	68
2.6.4 面向不同场景的充电策略优化与能量损失评估.....	71
三、项目创新点.....	82

一、项目的研究背景及意义

1.1 项目研究背景

在政策和市场的双重驱动下，近年来我国电化学储能装机量得到了爆发式增长，成为各方不可忽视的新赛道和新热点。2022年我国新增投运电化学储能电站达 7.86GWh，是 2021 年的 2.76 倍，2020 年的 4 倍，未来几年预计继续高速增长。然而，储能规模的不断扩大导致储能系统的可靠性问题愈发引起关注。电化学储能系统的电化学动态演变特性使其不同于常规电气设备，运行维护不当会造成性能衰减、寿命折损严重等问题，甚至导致安全事故，运维技术要求高、专业性强。而受制于成本约束，目前储能电站普遍存在“重建不重维”现象，运维投入不超过总成本的 5%。据调查，在 2022 年电化学储能停运情况中，计划停机次数占比仅为 30%，而非计划停机次数占比高达 70%，这显著减少了储能系统可用时间，降低了储能调度的运营效率和使用效益。更严重的是，电站的衰退与失效可能引起安全事故，全球自 2017 年至今已发生 70 余起储能电站安全事故，造成严重的经济损失甚至人员伤亡，对行业的发展带来严重的冲击。可见，储能系统的可靠性是其全生命周期安全高效运行的前提，更是掣肘整个行业快速发展的关键。

当前，提高电化学储能系统的可靠性面临以下痛点：

储能系统典型故障仿真技术不足。储能系统中组件多且运行关系耦合，单一组件例如电池、变流器等故障机制复杂，且受材料、结构和运行工况等因素影响，存在多尺度、多层次、多物理场强耦合性，现有的电池模型通常难以准确预测电池全生命周期

内性能衰退规律，电力电子设备等储能系统其他关键器件同样存在性能衰退，并与电池衰退相互影响，缺乏多组件系统的故障分析方法。储能系统可靠性评估手段较为欠缺。此前的电化学系统可靠性评估和故障诊断方法的研究大多集中在电池层级，对其他关键器件和管理系统故障的研究非常有限。据调研，电化学储能停运情况中，电池故障占比仅为 9%，而电池管理系统(BMS)、储能变流器(PCS)、能量管理系统(EMS)等故障占比分别可达 43%、13%和 4%。然而，目前业界尚无融合多种关键器件衰退机制的全系统可靠性评估模型和方法。

针对上述背景和行业痛点，本项目拟引入数字孪生技术，从多物理场信息、关键器件衰退机制、多器件协同的可靠性评估等方面出发，开发基于数字孪生技术的储能系统全生命周期监测平台，实现储能系统全生命周期高可靠性运维，解决储能系统可靠性痛点。项目具有以下先进性：

探明储能系统关键器件的衰退与失效机理，建立从器件到系统层面的多尺度健康参数退化数字孪生模型，利用数字孪生技术将电池、变流器、电力电子器件从单一分析到联合协同，开发融合多种器件衰退机制的储能系统级可靠性评估方法，填补系统级运维模型和故障诊断方法的技术空白。项目开发数字孪生系统和平台通过采集物理系统的数据并与虚拟系统同步更新，结合数据-机理融合的高精度数字孪生模型，实时准确地评估实际物理系统的运行状态，提前研判、识别和处理可能的系统故障和安全隐患，构建一体化数字孪生系统和监控平台，实现储能系统全生命周期精细化管理。

1.2 项目研究意义

随着新型储能能在能源电力转型中的作用和地位日益显现，新型储能产业呈现爆发式增长，受到产业各界的高度关注，成为各方不可忽视的新赛道和新热点。但当前电化学储能产业存在严重的“重建设轻运维”问题，面临产品质量需要加强、电站管理水平亟待提升等关键挑战。当前电化学储能系统的运维、可靠性分析以及故障诊断主要聚焦于储能电池，且以人工检查为主，存在智能化不足、成本高、故障处理能力差等痛点。传统储能系统上匮乏的传感数据以及单一的电池模型难以满足系统全生命周期的高可靠运维，导致储能系统故障、失效甚至安全事故时有发生，造成严重的经济损失甚至人员伤亡，极大地制约了行业的发展。

数字孪生技术是随着计算机技术与制造业的交叉融合而兴起的一种新兴技术，其通过数字化的手段构建一个与物理实体一样的虚拟模型，通过物理对象与虚拟模型间数据的交互来指导孪生体模型依据物理对象运行状态的改变而实时演化，通过仿真分析将预判结果反馈到数字孪生系统的诊断控制中心并帮助物理实体进行优化和决策。利用数字孪生技术有望显著提高储能系统的运维可靠性，但这需要先进传感技术、高精度器件衰退模型以及先进可靠性评估和故障诊断方法等多个层面的协同创新。

1.3 国内外研究现状

随着新型储能能在能源电力转型中的作用和地位日益显现，新型储能产业呈现爆发式增长，受到产业各界的高度关注，成为各方不可忽视的新赛道和新热点。根据国家电化学储能电站安全监测信息平台发布的《2022 年度电化学储能电站行业统计数据》，我国年新增电化学储能电站由 2017 年的 51MWh 增长至 2022 年的 7857MWh，五年增幅 154 倍。然而，2022 年电化学储能电站平均利用系数仅为 0.09（日均利用 2.27h、年利用 829h，折合成额定功率的运行时间与统计时间的比值），平均日利用指数为 32%（电站实际充放电量与规划设计充电电量的比值），这表明电站实际运行情况与设计日充放电策略差异巨大。同时，2022 年全年非计划停运 671 次，单位能量非计划停运次数 24.45 次/100MWh，相比 2022 年火电机组的非计划停运次数 0.35 次/（台·年）差距较大。上述数据表明，当前电化学储能产业存在严重的“重建设轻运维”问题，面临产品质量需要加强、电站管理水平亟待提升等关键挑战。

当前电化学储能系统的运维、可靠性分析以及故障诊断主要聚焦于储能电池，且以人工检查为主，存在智能化不足、成本高、故障处理能力差等痛点。特别的，统计数据显示（图 3.1），2022 年全国电化学储能系统停机事故中电池故障仅占 9%，而 BMS、PCS、网络通讯等故障则分别占比 43%、13%、10%，特别是 PCS 故障引起的每次停运时间达到 60.98 小时。然而，目前业界对 PCS 等关键器件衰退机制的探究仍十分有限。即便是在电池本体层面，考虑其多尺度、多物理场、多失效机制耦合的特征，传统储能系统上匮乏的传感数据以及单一的电池模型难以满足系统全生命周期的

高可靠运维，导致储能系统故障、失效甚至安全事故时有发生，造成严重的经济损失甚至人员伤亡，极大地制约了行业的发展。

数字孪生技术是随着计算机技术与制造业的交叉融合而兴起的一种新兴技术，其核心思想是通过数字化的手段来构建一个与物理实体一样的虚拟模型，通过物理对象与虚拟模型间数据的交互来指导孪生体模型依据物理对象运行状态的改变而实时演化，通过仿真分析将预判结果反馈到数字孪生系统的诊断控制中心并帮助物理实体进行优化和决策。对于储能系统而言，可以通过数字孪生技术将储能系统关键器件通过数字孪生将实时传感器数据与性能模型结合，随运行环境变化和物理储能系统性能的衰减，构建出自适应模型，精准监测储能系统器件和整体的性能变化，并结合历史数据和性能模型，进行故障诊断和性能预测，实现数据驱动的性能寻优。因此，利用数字孪生技术有望显著提高储能系统的运维可靠性，但这需要先进传感技术、高精度器件衰退模型、以及先进可靠性评估和故障诊断方法等多个层面的协同创新。

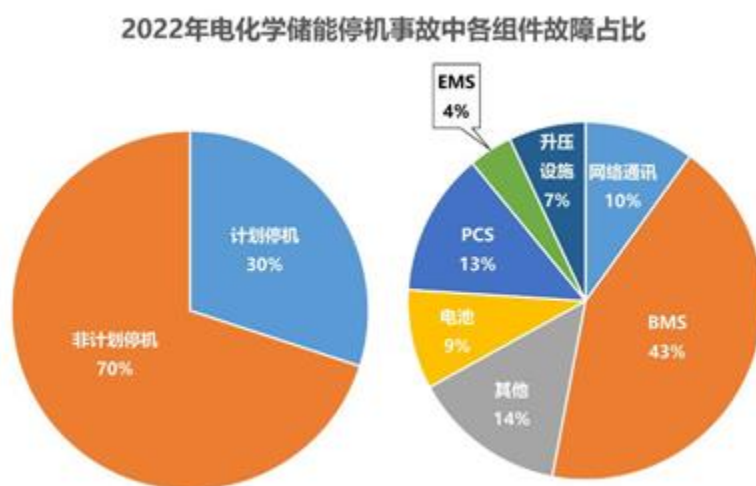


图 1 2022 年全国电化学储能系统停机事故中各组间故障占比

在储能电池多物理场传感方面，法国法兰西学院[1]、中国台湾元智大学[2, 3]、葡萄牙阿威罗大学[4]等高校通过在电芯内布置光纤布拉格光栅（FBG）传感器实现了电池内部应变、温度、电解液浊度等信号的在线测量，并通过挖掘电池内部信息来丰富模型输入端的数据以提高电池状态估计和故障预警的精度。美国普渡大学[5]、北京理工大学[6]等采用在电池内部植入 RTD、NTC 等温度传感器实现了电池内部温度的测量，但由于电池内部电解液的强腐蚀性，这类嵌入式传感器存在长周期可靠性低、影响电池性能等共性问题。日本大阪市立大学[7]利用膨胀仪和声发射装置测量了锂离子电池充放电过程中的厚度变化，美国密西根大学[8]利用非色散外红二氧化碳传感器检测了电池过充状态下 CO₂ 的排放情况，证明了其在热失控气体检测方面的快速响应和有效性。华中科技大学[9]通过超声技术研究了软包电池的电解液浸润过程和局部电解液干涸问题，突出了其在电池失效机制探究方面的意义，然而上述传感器所使用的设备都较为复杂，且对测试环境要求较高，在实际工况下效果会大打折扣，因此，亟须开发出能够在复杂储能工况下长期稳定运行的、包含电池多维度信息同时又具有较强实际应用可能的高精度多物理场传感方案。

在储能电池衰退和状态预测模型方面，英国帝国理工学院[10]、美国福特公司[11]、美国宾夕法尼亚州立大学[12]、德国奥芬堡应用技术大学[13]、亚琛工业大学[14]等通过开发多物理场耦合的机理模型来对锂离子电池的插层膨胀、析锂、SEI 增长、应力诱导的 SEI 破碎等电池老化机理进行建模，实时描述锂离子电池内部发生的动态演化过程，以一种可解释的“白箱”模型对

电池的剩余容量和寿命等进行评估，进而优化电池设计。然而，全阶机理模型通常要求解多个强耦合的偏微分方程组，计算量很大，很难实际应用[15]。英国华威大学[16]提出了一种考虑电池老化趋势以及相应的工作温度和放电深度的降阶模型，在高斯过程回归的协方差函数的基础上，建立了两个相关的数据驱动模型来估计电池容量。香港大学[17]提出一种基于相关向量机(relevance vector machine, RVM)模型的锂离子电池容量预测方法，采用RVM对电池的老化数据进行训练，估计电池的剩余寿命；赫瑞瓦特大学[18]着重于特征构造，从不同电池、不同圈数的充电曲线中提取出30个富有价值的特征，利用四种传统的数据驱动方法来预测电池寿命。基于数据驱动的方法虽然有着较高的预测精度并且不需要额外的电化学知识，但其面临着模型复杂度高、实时性差、对数据集要求高且外推性能差等问题。单独的基于机理或基于数据驱动模型都存在着各自的优点和缺点，采用适当的方法将二者联立应用可以很好地发挥机理模型的外推能力和数据驱动模型的灵活性以及高维运算能力。美国加州丰田研究所[19]利用数据-机理模型的耦合方式将模型的结构分为五类，每类结构都有着其各自的优缺点及实施所面临的困难，为数据-机理融合模型的开发提供了一些启发。随着储能电池对状态估计、故障预警精度、实时性以及可靠性的不断提高，基于多源传感数据的多模型融合的可靠性分析及故障诊断将会是未来储能系统的主要发展趋势。

在储能变流器的故障诊断方面，主要的故障预测算法包括时间序列、神经网络以及支持向量回归三种：时间序列预测方法对

序列变化比较均匀的短期预测情况较为理想，优点是所需历史数据少，工作量小，但该方法在非线性预测中预测精确度较差。神经网络方法在非线性领域中得到了广泛的应用，但该方法存在容易陷入局部最优、收敛速度慢等缺点。支持向量回归预测解决了神经网络容易陷入局部极小点的问题，所需训练样本数据少，且泛化能力较强，预测准确度较高。此外，现阶段 PCS 故障预测大多是对电路中关键元器件的故障预测，如开关器件、电解电容等，故障特征参数多为元器件的特征参数，而对电路级别的故障预测研究很少，并且缺乏面向真实应用场景的研究和验证。

在基于数字孪生的电池运维技术方面，国内外都还处于初期探索阶段，目前的研究主要聚焦于电池本体而非系统的数字孪生模型，通过在云端、边端部署不同复杂度、精度、响应速度的电池模型，考虑不同层级之间数据颗粒度的差异，开发模型之间数据融合方案和通讯协议以最优化电池的管理及运维[20, 21]。英国帝国理工学院[22]于 2020 年提出电池数字孪生体概念，并将先进电池建模、车载诊断工具、数据驱动的建模方法等融合在一个共同框架内，提高了锂离子电池的管理效率。德国亚琛工业大学[23]开发了“电池数字孪生器”软件工具，建立了锂离子电池数字孪生模型，可以预测电池的寿命和性能变化；英国牛津大学[24]开发了世界上首个兆瓦级储能系统数字孪生模型，模拟了一个由 18900 个独立电池组成的 1 MWh 电网电池系统，突出了数字孪生技术在提高系统性能、延长寿命方面的重要性；新加坡国立大学[25]分析了大规模储能系统实现数字孪生的主要挑战，提出从电池单体到系统多层级的数字孪生技术框架；北京航空航天大学[26, 27]

对数字孪生技术进行了前期理论研究以及应用实践，并总结了数字孪生的五大类关键技术、十大应用领域及数字孪生驱动的六条应用准则；北京理工大学[28]基于数字孪生理论，提出了智能电池管理系统中电池数字化建模、实时状态估计、动态充电控制、动态热管理和动态均衡控制的解决方案。上海海事大学基于五维数字孪生模型和UNISON框架构建了面向实际应用的数字孪生模型并成功应用于新能源动力电池的研究中。

基于上述研究可以发现，目前全球对电化学储能数字孪生技术的研究极为火热，但均处于起步阶段，不同研究机构对数字孪生这一概念的理解以及应用手段、目的均不同，大多数针对数字孪生的研究都仅限于提出一个复杂且难以在实践中应用的方案、路线，缺乏系统级研究和实际应用验证，建立储能系统中多种关键器件的数字孪生体并将其有机地融合将会是当前电化学储能运维领域的主流发展趋势和技术制高点。

二、主要研究内容

2.2 任务1 基于数字孪生的储能系统典型故障仿真模块研究

2.2.1 概述

为提升储能系统对典型故障的仿真与预测能力，本任务提出了一种基于电池特征与故障响应耦合的储能系统多参量故障模拟验证模块。针对小样本故障数据稀疏的问题，开发了综合故障模拟框架，通过多窗口时序划分、快速傅里叶变换（FFT）结合随机频带屏蔽、高斯滤波及电压电流正弦波仿真，生成多样化的故障模拟数据，为故障分析提供可靠支持。结合深度学习技术，利用卷积神经网络（CNN）与长短时记忆网络（LSTM）提取电池动态数据的局部模式和时序依赖特征，辅以动态自编码器（DYAD）挖掘健康状态核心信息，构建多维故障特征模型。通过耦合电池特征与故障响应，实现了多参量故障的精准模拟与验证，为储能系统的故障分析与早期预警提供了技术支持。

本任务通过融合机理模型和数学模型，搭建了储能系统的故障模型，实现了对典型故障的仿真与预测。利用数字孪生技术，构建了储能系统的机理模型，通过多模态数据（如电压、电流、温度、初始安全间隔 SEI 厚度及触发场景）映射物理实体的运行状态，并采用标准化处理方法对数据进行预处理。结合深度学习技术，利用 CNN 与 LSTM 提取电池动态特征，辅以 DYAD 挖掘核心健康信息，构建多维故障特征模型。同时，基于动态自编码和物理神经网络，生成三维热

流分布图和温度导数分布图，实现热失控特征的时空可视化，为储能系统的故障仿真与早期预警提供了技术支持。

2.2.2 基于电池特征与故障响应耦合的储能系统多参量故障模拟验证模块

下图 1 展示了本研究开发的基于电池特征与故障响应耦合搭建储能系统多参量故障模拟验证模块的总体框架。针对特征提取阶段，本研究设计了一种融合深度学习网络与动态特征分析的创新方法。首先，通过卷积神经网络（CNN）对电池动态数据的局部模式进行高效提取，捕捉数据在局部范围内的变化规律；其次，结合长短时记忆网络（LSTM）进一步挖掘时间维度的依赖关系以及数据的全局动态特性，从而更全面地捕捉电池的动态变化。此外，采用动态自编码器（DYAD）进一步提取电池健康状态的核心信息，包括信息熵和相空间特征。这些高层次的抽象特征能够反映电池内部的复杂动态行为。根据 CNN-LSTM 模型的时间依赖建模，本研究还引入了新的特征构建方式，即通过计算电池数据中最大单体电压与最小单体电压的差值，形成一个新特征——电压差。该特征与原始数据特征相结合，构成了新的特征组合，与仅使用原始特征相比，这种方法能够提供更深层次、更具代表性的时间依赖特征。值得注意的是，电流和电压等原始特征往往只能反映电池在单一时间点上的瞬时状态，难以捕捉电池在复杂非线性动态关系中的演变规律。而本研究通过

CNN+LSTM 和 DYAD 的联合特征提取，不仅克服了这一局限，还能更好地适应不同数据的分布特性。这种创新性特征提取方法有效降低了模型对特定数据分布的依赖性，大幅提升了故障检测任务的泛化能力。为提升储能系统对过放电和热失控等故障的仿真与预测能力，本研究基于真实实验数据（图 4），开发了一种多参量故障模拟验证模块（图 3）。该模块通过数据驱动方法，融合深度学习与动态特征分析，利用 CNN 提取电池动态数据的局部模式，LSTM 挖掘数据全局动态特性，并结合 DYAD 引入“电压差”等新特征，构建更具代表故障模拟与验证，为储能系统安全运行提供技术支持。

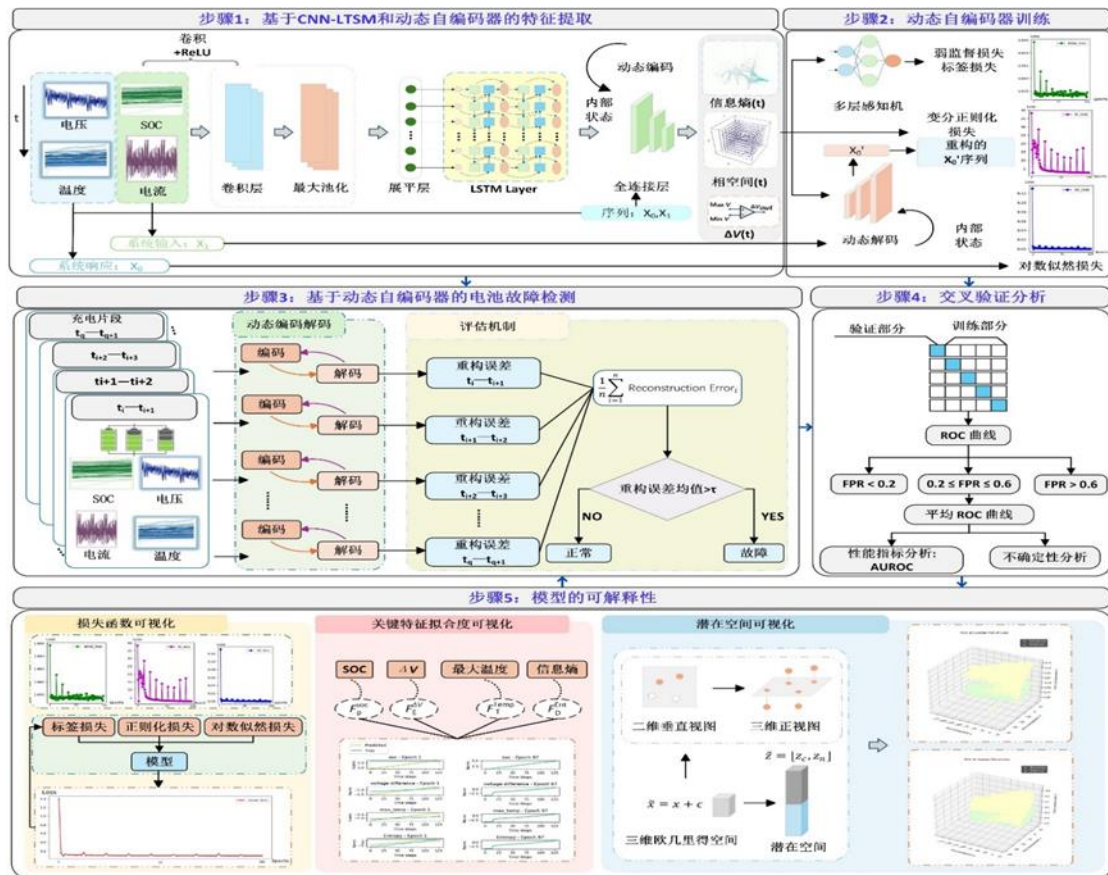


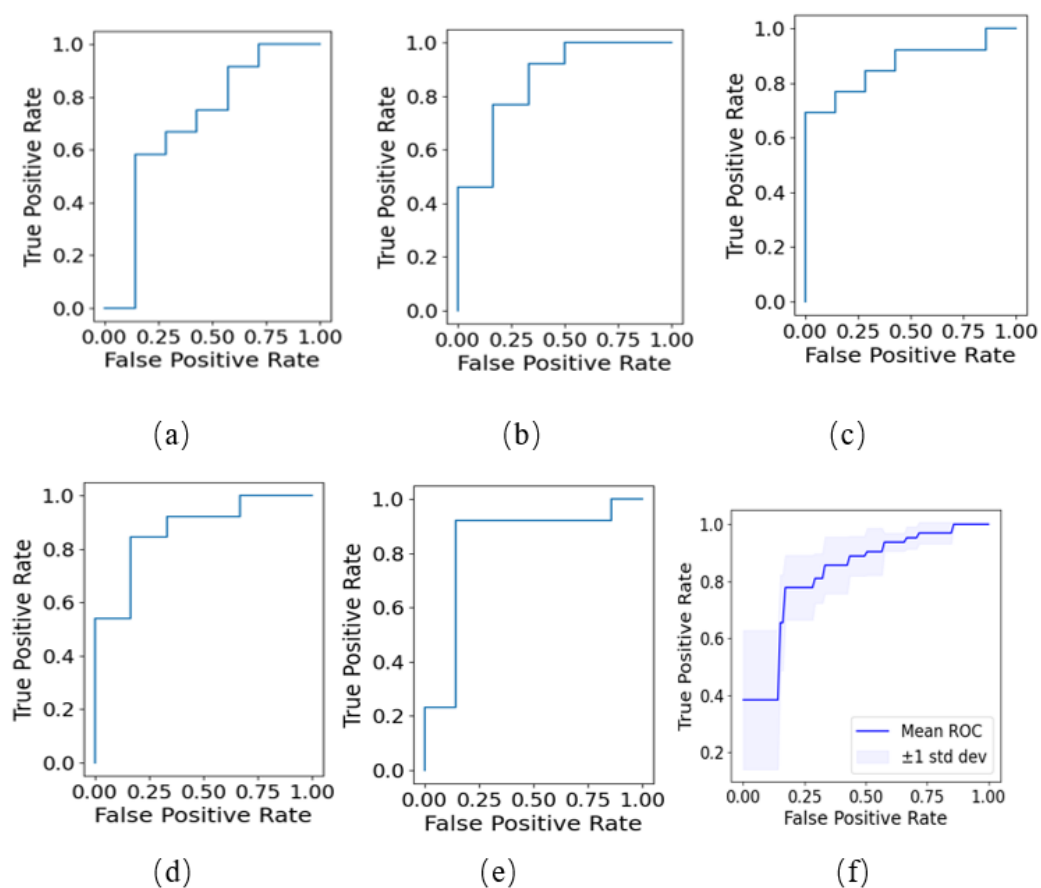
图 1 基于动态自编码器电池故障检测技术路线图

表 1 故障分类任务指标

指标名称	指标范围	公式	说明
准确率	90% ~ 99%	$Accuracy = (TP+TN) / \text{总数}$	正确分类样本所占比例
精确率	88% ~ 98%	$Precision = TP / (TP+FP)$	模型判定为故障中，实际为真的比例
召回率	85% ~ 97%	$Recall = TP / (TP+FN)$	所有实际故障中被模型识别出来的比例
F1 分数	87% ~ 96%	$F1 = 2 \cdot (P \cdot R) / (P+R)$	精确率与召回率的调和平均
AUC-ROC		曲线下面积	用于二分类模型的整体判断能力

图 2 显示了五重交叉验证结果，展示了模型在每次迭代期间根据不同的误差阈值动态选择受试者工作特征（ROC）曲线。在所有验证折叠中，ROC 曲线始终聚集在左上角附近（AUROC=88.7±5.8），表明模型在不同分区下性能稳定且泛化性强。通过五种受控实验配置（对应于图 2a-e），本研究系统阐明了重建误差阈值选择对锂离子电池故障检测效能的控制机制。我们的实验结果表明，阈值配置直接调节了两种工作范式的灵敏度-可靠性权衡：零误报安全模式（FPR=0）和在线监测平衡模式（FPR=0.15）在基线配置（图 2a）中，高估的阈值配置完全抑制了绝对安全约束下的早期故障识别能力（TPR=0）。优化的第五种配置（图 2e）通过动态阈值优化实现了显著的性能：在零误报场景中保持 TPR=0.22，同时在 FPR=0.15 时达到 TPR>0.92. ROC 曲线在低

假阳性状态 ($FPR < 0.2$) 中表现出陡峭的上升轨迹, 表明该模型能够通过控制瞬态误报的容忍度来捕获初期故障。



a-e: 不同阈值选择策略下的 ROC 曲线动态变化

f: 含不确定区间的平均 ROC 曲线

图 2 自适应误差阈值选择下的 ROC 轨迹演变

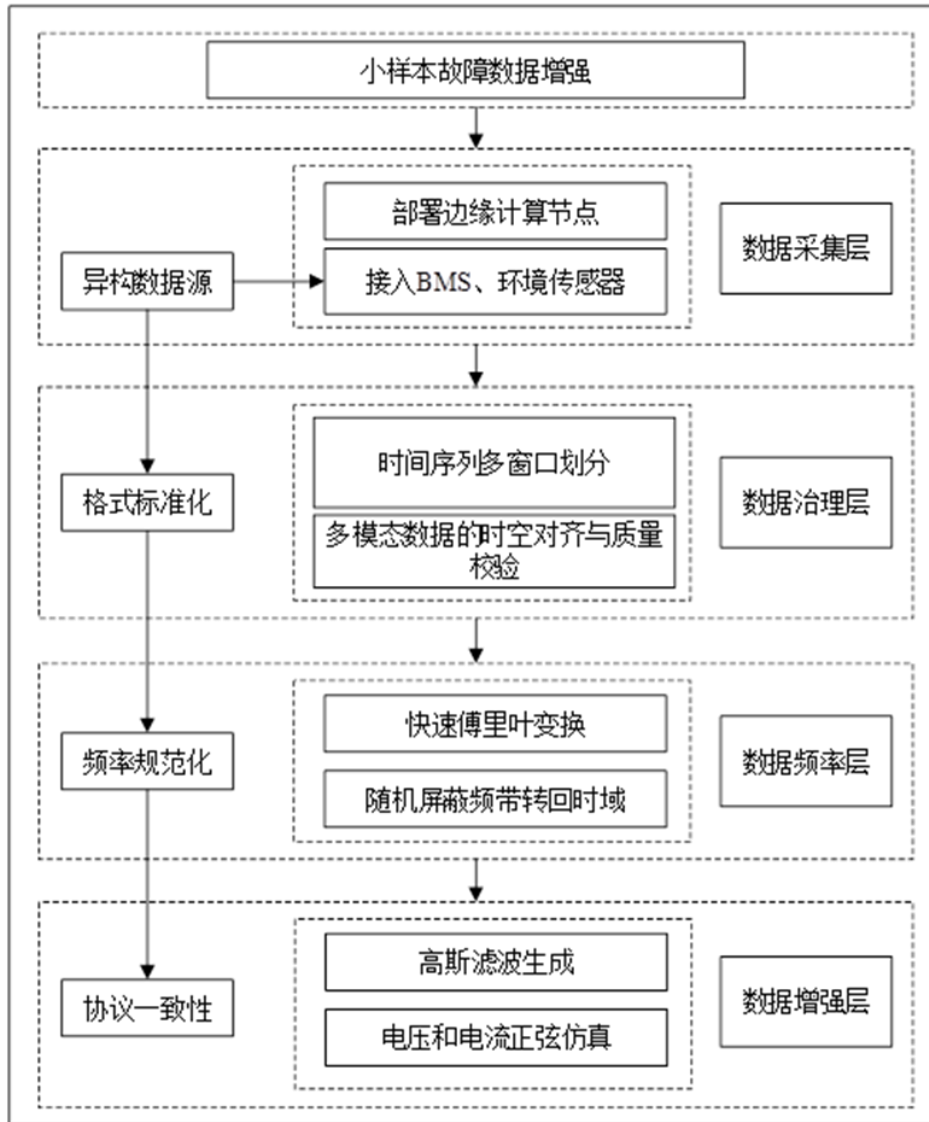



图 3 多参量故障模拟验证模块技术路线



a. 过放电实验前电池外观 b. 过放电实验后电池外观
c. 热失控实验前电池外观 d. 热失控实验后电池外观

图 4 典型故障所做实验电池外观图

(1) 结合随机频带屏蔽

快速傅里叶变换 (FFT) 用于将时域故障信号转换到频域, 以便对特定频率分量进行操作。对原始时序数据 (如电压或电流) 应用 FFT, 分解信号为其频率分量。随机选择一个或多个频带, 并将其对应的 FFT 系数设为零, 以屏蔽这些频率。通过逆 FFT 将修改后的频谱转换回时域, 生成增强信号。该技术在频域中引入扰动, 能够模拟故障特性或测量条件的变化。例如, 屏蔽高频带可模拟高频分量减少的故障, 而屏蔽低频带则可表示基线趋势变化的故障。

(2) 高斯滤波

高斯滤波用于平滑时序故障数据, 生成噪声减少或时域特性改变的增强样本。生成一个标准差 σ 在预定范围内随机选择的高斯核。将原始时序数据与高斯核进行卷积, 得到平滑信号。通过调整 σ , 可以控制平滑程度, 从而生成反映不同噪声水平或故障进展速率的增强数据。

(3) 电压电流正弦波仿真

为进一步丰富故障数据集, 我们使用正弦波生成合成电压和电流信号, 以近似某些振荡性故障行为。在指定范围内随机选择正弦波参数, 包括幅度 A 、频率 f 和相位 ϕ 。

使用正弦波方程生成合成时序数据:

$$\begin{aligned} V(t) &= A_v \cdot \sin(2\pi \cdot f_v \cdot t + \phi_v) + \epsilon_v \\ I(t) &= A_i \cdot \sin(2\pi \cdot f_i \cdot t + \phi_i) + \epsilon_i \end{aligned}$$

其中,

$V(t)$ 、 $I(t)$: 分别为电压和电流随时间 t 变化的合成信号;

A_v 、 A_i : 电压和电流的幅度, 随机在指定范围内选择;

$f-v$ 、 $f-I$: 电压和电流的频率，随机在指定范围内选择；
 $\phi-v$ 、 $\phi-I$: 电压和电流的相位，随机在 $[0, 2\pi]$ 范围内选择；
 $\epsilon-v$ 、 $\epsilon-I$: 可选的加性噪声，用于增加信号真实性，通常为高斯噪声或零。




图 5 故障数据模拟前后数据分布

2.2.3 搭建机理模型和数学模型融合驱动的储能系统故障模型

为提升储能系统的安全性和可靠性，本研究提出了一种融合机理模型和数学模型的故障检测方法（图 1），针对热失控等典型故障进行机理分析和风险评估。通过构建储能系统的机理模型并结合数学模型的优化，实现了故障特征的时空分布可视化和早期预警。研究利用机理模型和数学模型的融合，搭建了储能系统的故障检测框架：

(1) 机理模型：基于电池的热动力学和电化学原理，构建了描述热通量和温度变化率的物理仿真框架，模拟电池在不同工况下的热行为。

(2) 数学模型：通过数据驱动方法，分析电压、温度、初始安全间隔（SEI 厚度）等多模态数据，提取关键特征参

数，如温度变化率（ dT/dt ）和热通量，并优化故障检测阈值。

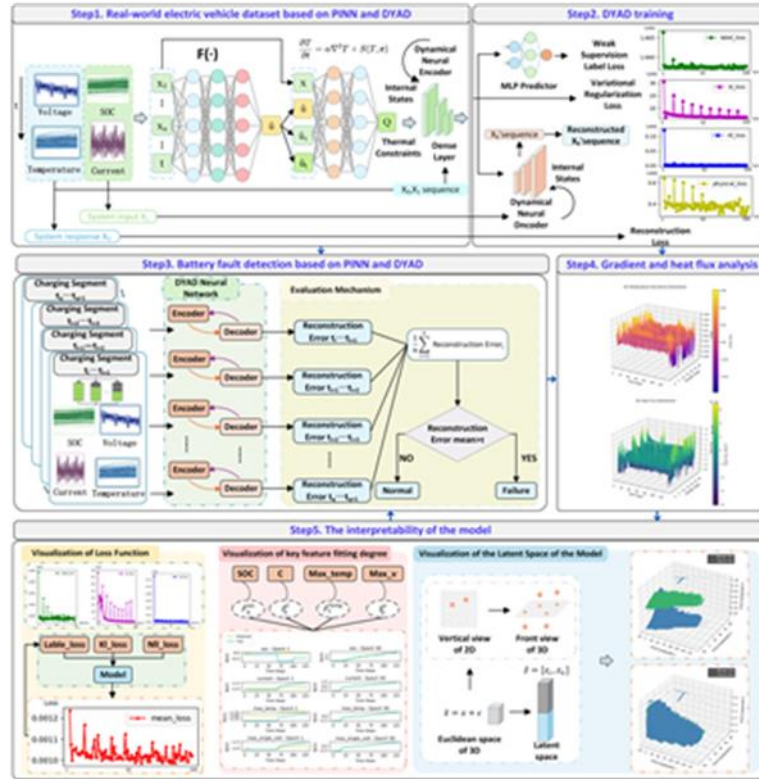


图 1 基于动态自编码和物理神经网络的电池故障检测技术路线图

利用数字孪生技术，构建了储能系统的三维热流分布图和三维温度导数分布图。三维热流分布图（图 2a）：展示了热通量（单位： W/m^2 ）在时间（0-120 步）和空间（0-40 步）上的分布，颜色从深蓝（低热通量）渐变至深红（高热通量），反映了热通量的时空变化。三维温度导数分布图（图 2b）：展示了温度变化率（ dT/dt ，单位： K/s ）在相同时间和空间维度上的分布，颜色从深蓝（低变化率）渐变至深红（高变化率），突出了温度剧烈变化的区域。从分布图中提取关键特征参数，包括温度变化率（ $dT/dt > 0.04 K/s$ ）、热通量（ $> 3 W/cm^2$ ）和内阻升高，用于后续热失控检测和分析。

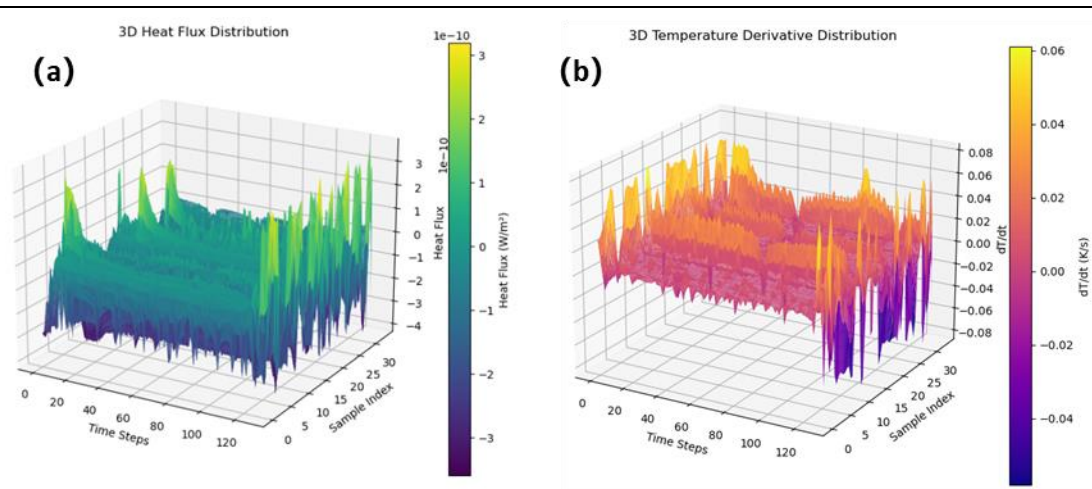


图 2 a. 三维热流分布图 b. 三维温度导数分布图

(2) 热失控阈值确定

通过对特征参数的分析，研究确定了热失控的检测阈值（表 1），

表 1 初定安全故障检测阈值

故障类型	初定安全阈值	触发场景
热失控	温度导数 (dT/dt) $> 0.04K/s$ 、热通量、 热通量 $> 3W/cm^2$	SEI 膜分解、电解液
容量衰减	$< 80\%$	内阻升高

这些阈值基于储能系统热失控的物理特性设定。

在多次验证集中（3-10 次，每次 1 个验证集），系统对热失控的检测率达到 100%（ $TPR=1.0$ ），即所有验证集均能正确识别热失控。通过调整阈值，系统在误报率（FPR）为 15% 时，检测率仍保持在 95% 以上（ $TPR > 0.95$ ），表明阈值设置具有较高的鲁棒性。

利用 ROC 曲线（图 3）（真阳性率 TPR vs. 假阳性率 FPR）评估不同阈值下的检测性能。曲线包含 6 条曲线（对应均值和标准差范围），分析表明在 $FPR < 0.2$ 的阈值区间内，系统检测性能最佳，能够有效平衡检测率和误报率。

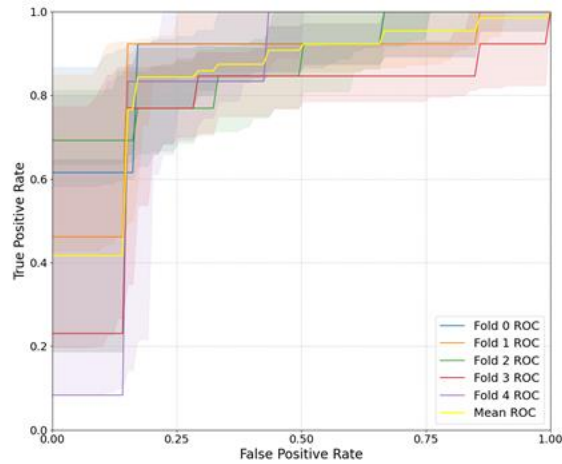


图3 含不确定区间的五个不同阈值的 ROC 和平均 ROC 曲线

通过优化的阈值设置，系统能够在热失控发生前提供可靠的预警信号，满足电池管理系统（BMS）对长期稳定运行的需求。预警信号基于实时的温度变化率和热通量监测生成。研究通过数字孪生技术实现了对热失控特征参数的精准监控，显著降低了误报率（ $FPR < 0.2$ ），从而提升了储能系统的整体安全性。热流分布和温度导数分布的可视化分析进一步帮助识别潜在风险区域。

2.2.4 PCS 数字孪生建模方法研究

2.2.4.1 PCS 孪生建模概述与整体思路

PCS（Power Conversion System）孪生建模旨在构建一个能在虚拟空间中准确反映物理 PCS 系统运行特性、故障状态和寿命演化过程的数字模型**错误!未找到引用源。**。通过融合电气建模、数据驱动与智能算法等方法，实现对 PCS 系统关键组件（如直流支撑电容、电感、功率器件等）性能的实时感知、行为预测和健康评估。

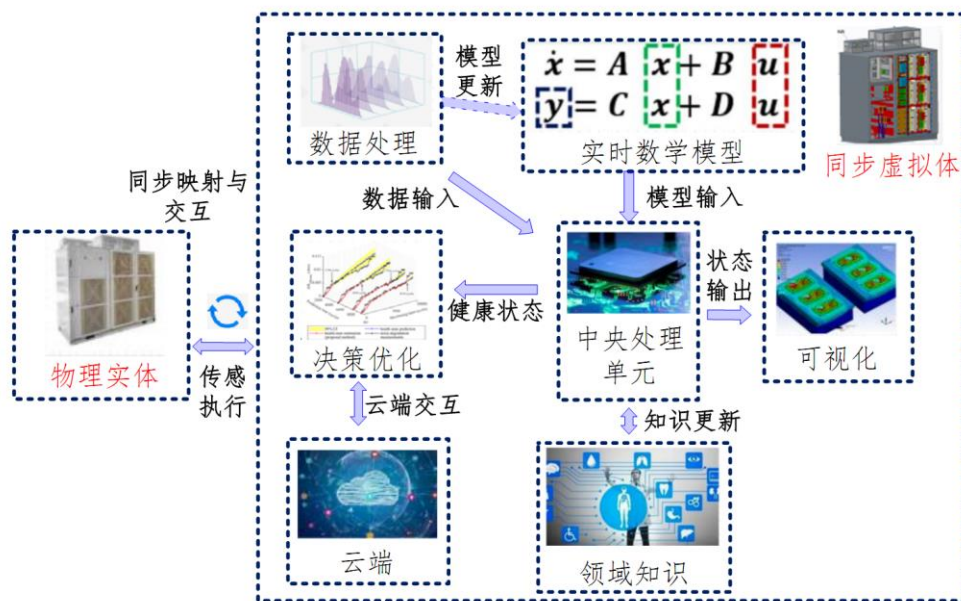


图1 数字孪生系统示意图

基于数字孪生的状态监测系统具有以下优势：1. 可减少传感器的投入数量。2. 搭建并依赖于实时电路模型，参数监测可实时在线运行。3. 通用性强，由于将整个电路模型结构的信息加入了监测计算过程中，几乎不依赖于特定的电路结构。4. 除测量电路外，不会引入其他的额外电路。5. 不会影响变流器系统的正常工作状态。与结温检测手段相比，该方法主要具有以下优势：1. 实时运行。2. 模型具有一定的物理意义。3. 无需破坏模块封装。4. 无需额外的控制电路。同时，整个数字孪生模型本身是数学模型的集合，因此其扩展性很好，大多数能够实时运行的方法均可通过数字孪生系统集成。因此，对PCS的关键部件故障预测和健康管理研究对其健康运行具有重要意义。

本研究中 PCS 孪生建模整体思路：首先，基于 PCS 系统的电气拓扑结构建立物理仿真模型，包括变流器控制逻辑、PWM 调制策略、LCL 滤波器、负载及并网接口等模块，确保系统仿真具备结构一致性和电气可解释性；其次，在充分采集 PCS 系统运行数据的基础上，提取关键特征量（如母线电压纹波、电流谐波、电容温度、电流应力等），结合设备退化机理，构建电容、电感等元件的参数退化模型；第三，融合神经网络、粒子群优化等智能建模方法，对系统响应数据进行非线性拟合与回归，建立多输入多输出的性能预测模型，实现元件老化趋势识别与寿命预测；最后，借助数字孪生平台，将仿真模型与实时数据同步，实现系统状态的虚实映射、在线诊断与预警，形成“物理-数据-算法”闭环。

数字孪生技术具备信息物理深度融合、虚实交互友好、模型自适应校正等优点。近年来有学者开展了数字孪生技术在电力电子化电力系统相关方面的应用研究，但目前为止，数字孪生技术在储能系统及 PCS 方面的相关研究非常少。

2.2.4.2 基于零序注入的电容数字孪生建模方法

本研究提出一种结合数字孪生技术的 DC-Link 电容在线监测方法。在 TNPC 三电平逆变器的闭环系统中，通过注入低频零序电压信号，引导系统产生可观测响应，再利用构建的电容数字孪生体对电压信号进行动态建模。采用 PSO-BP 神经网络算法进行状态辨识，实现对电容参数（如电容值和

ESR) 的无电流传感辨识。相比传统依赖纹波电流的监测手段, 本方法简化了传感器设计, 提高了系统的可靠性与辨识精度, 并具备良好的实时性与可扩展性。

1、BP 神经网络

BP 神经网络 (Backpropagation Neural Network) 是一种前馈型多层神经网络, 其训练依赖于误差反向传播机制, 一般包括输入层、输出层和隐含层。其神经网络结构图如图 1 所示。




图 2 BP 神经网络结构图

网络通过计算预测结果与目标值之间的偏差, 并利用梯度下降法对权重和偏置参数进行不断优化调整^{错误!未找到引用源。}, 从而实现函数近似、分类或预测任务。BP 神经网络的训练过程如下所示:

1) 信号的向前传播: 输入数据首先由输入层传递到隐藏层, 并在传递过程中加权处理, 再由激活函数 f_1 实现非线性映射转换。则隐藏层第 n 个神经元的输出结果为:

$$y_n = f_1\left(\sum_{m=1}^p \omega_{nm}x_m + b_n\right) \quad (1)$$

而隐藏层的输出 y_n 传递到输出层，并在该阶段加权处理，再由激活函数 f_2 进行非线性映射转换，则输出的第 i 个神经元的结果为：

$$y_i = f_2\left(\sum_{n=1}^s \omega_{ni}y_n + b_i\right) \quad (2)$$

式中： x_m 表示输入层第 m 个节点的输入变量； ω_{nm} 表示输入层与隐藏层之间的权重值； ω_{ni} 表示隐藏层与输出层之间的权重值； b_n 和 b_i 分别为隐藏层和输出层的偏置值； f_1 和 f_2 分别为隐藏层和输出层的激活函数。

2) 误差的反向传播：首先计算输出层的误差，并将其传递至隐藏层，再根据每一层的误差信息，动态调整对应的权重与偏置参数。输出层误差计算公式：

$$E = \frac{1}{2} \sum_{i=1}^s (t_i - y_i)^2 \quad (3)$$

式中： t_i 为输出层真实值。

网络在 1) 和 2) 的交替过程中持续调整参数直至收敛。

此算法作为经典算法之一，具备较强的非线性函数逼近能力，但其存在易陷入局部极小值的问题^{错误!未找到引用源。}，且对初始权重敏感，训练过程可能较慢，可能影响整体检测效果。

2、BP 神经网络

粒子群算法（PSO）算法是一类源于自然界鸟群、鱼群协同行为的群体智能优化方法。该算法在解空间内随机生成多个“粒子”作为潜在解^{错误!未找到引用源。}，通过不断迭代更新，粒子依据其最优经历以及全局最优信息更新参数，从而逐步向最优解靠近。该算法具备较强的全局搜索能力，且算法结构简单，响应速度快。

基于 BP 算法的局限性，本文引入了 PSO-BP 算法，此算法利用 PSO 算法来优化 BP 神经网络的初始参数，从而改善网络的整体性能。而在 PSO 优化 BP 算法中，适应度函数是用来评价每个粒子性能的核心指标，其设计直接影响到 PSO 的搜索效率和最终模型的性能。本文中适应度函数选用均根方误差（MSE）：

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2 \quad (4)$$

PSO-BP 具体步骤（如图 2 所示）如下^{错误!未找到引用源。}：

- 1) 将神经网络的所有权重和偏置编码为一个粒子，使每个粒子代表网络的一组潜在解。
- 2) 随机分布粒子于解空间，并初始化其相关参数设置。
- 3) 构建适应度函数评估指标。

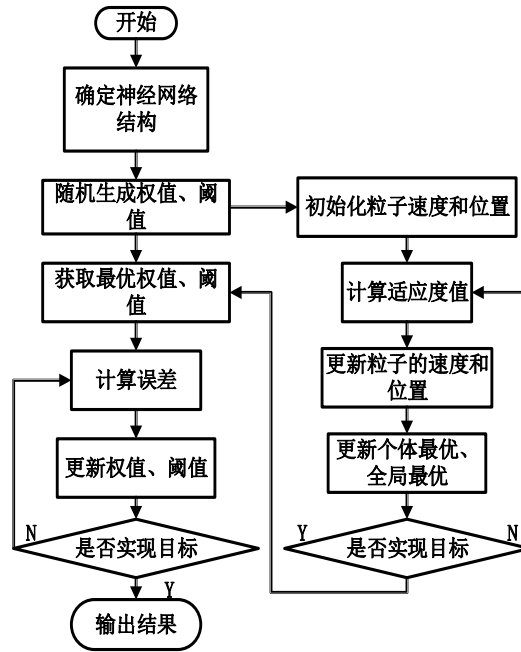


图3 PSO-BP 算法流程图

- 4) 根据当前结果，更新每个粒子的最优解。
- 5) 更新粒子速度与位置。粒子速度更新公式如式 (5)：

$$v_{i,d}(t+1) = \omega v_{i,d}(t) + c_1 r_1 [p_{i,d} - x_{i,d}(t)] + c_2 r_2 [p_{g,d} - x_{i,d}(t)] \quad (5)$$

粒子位置更新公式如式 (6)：

$$x_{i,d}(t+1) = x_{i,d}(t) + v_{i,d}(t+1) \quad (6)$$

式中： ω 为惯性因子， c_1 和 c_2 为学习因子， r_1, r_2 为 0 到 1 之间的随机数， $p_{i,d}$ 为个体最优解， $p_{g,d}$ 为全局最优解。 $x_{i,d}(t)$ 表示当前粒子位置（BP 网络参数）的第 d 个分量。

6) 用新位置对应的参数运行 BP 神经网络，计算新的适应度值，并更新个体最佳和全局最优解。

7) 重复步骤 4) 到 5)，直至迭代次数达到设定上限，或适应度达到预定的阈值，获得优化后的权值及阈值。

8) 将全局最佳参数作为 BP 网络的初始权重和偏置, 对神经网络进行进一步精细训练。

3、T 型逆变器电容数字孪生建模流程:

首先, 选定检测信号为 T 型三电平逆变器 DC-Link 电容纹波电压, T 型三电平逆变器 DC-Link 故障监测流程如下:

Step1: 数据采集。采集不同电容退化程度下的 DC-Link 电容纹波电压故障特征。

Step2: 数据归一化。即将原始数据进行无量纲化处理, 以消除不同特征量纲差异对模型训练的影响。

Step3: 确定 BP 网络结构。将 BP 网络中的所有权重和偏置平铺成一个一维参数向量, 此向量就是 PSO 算法优化的目标变量。

Step4: PSO 算法迭代优化。设定粒子群优化算法的相关参数, 并设计适应度函数, 启动迭代求解直至满足收敛条件。

Step5: BP 神经网络精细训练。

4、电容数字孪生建模验证结果

在 Matlab/simulink 平台上搭建并网 T 型三电平逆变电路图, 设置直流侧电压 750V, 电解电容 5600 μ F, 输出频率 50Hz, 开关频率 16kHz, 电路拓扑结构如图 3 所示。

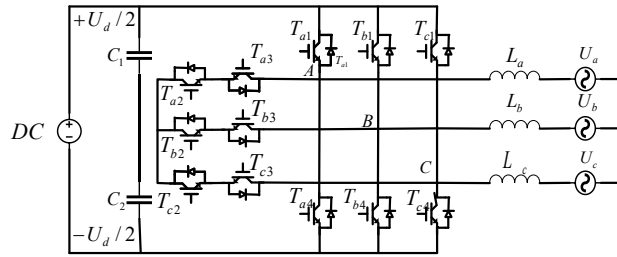


图4 TNPC 拓扑

但是在实际监测中，电容的纹波电压受电容值和其等效串联电阻（ESR）的影响较小。这主要是因为，在稳态工作条件下，电容的充放电特性相对稳定，而 ESR 主要影响高频开关瞬态过程。因此，仅依靠电容本身的特性难以显著增加或调节纹波电压的波动幅度。

为了在系统中引入额外的纹波电压波动，可以采用一种有效的方法——在调制信号中叠加一个小的零序分量（Zero-sequence Component）。这一做法可以人为地在三相系统的调制策略中引入一定的零序电压，使得母线电容的电压纹波得到增强或者更具特定模式的波动。当在调制信号中引入额外的零序电压 u_{m0} 时，不会影响三相电压的线电压分量，但会改变中点电位，进而影响母线电压的等效波形，使得电容上的纹波电压产生可控的波动。

具体注入方法如图 4 所示，注入频率为 115Hz，幅值为 5V。

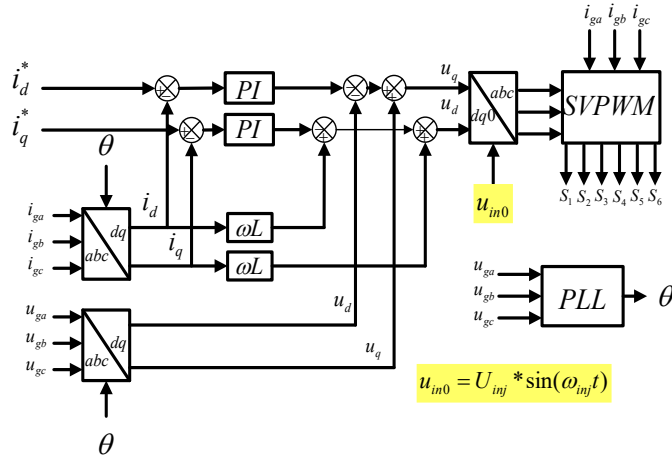


图5 零序电压注入框图

在这种注入方式下，零序电压均匀叠加到各相调制参考上，从而不会影响负载端的交流输出。这样能够在不破坏整体稳态的前提下，调动电容的充放电过程，进而使直流侧电压出现可控的波动，且可以根据实际测试需要调整扰动的幅值和频率，确保在保证系统稳定性的前提下获取足够的动态信息，从而更好地监测电容特征值。

PCS 直流母线上、下侧电容数字孪生模型搭建完成后，对其进行了性能测试，利用预置的电容值、ESR 值老化曲线，对孪生模型参数状态跟踪情况进行测试，测试情况如下：

在搭建好的模型中采集电容纹波电压，使用标称值 5600 μF 、等效电阻 $5\text{m}\Omega$ 的电解电容。电容值下降为标称值的 80% 判定为失效^{错误!未找到引用源。}，则将 C_1 、 C_2 退化程度分为 0~20%，20%~40%，40%~50% 三种故障程度；而电容等效电阻增长为标称值的两倍时，判之为失效，则将 R_{ESR1} 、 R_{ESR2} 增长范围分为 0~50%，50%~100%，100%~150%，150%~200% 四种故障程度，

最终模拟 144 种故障类型，每种故障类型采集 20 组数据，部分故障类型如表 1 所示。

表 1 储能逆变器部分故障类型

故障名称	C_1 退化程度 (%)	C_2 退化程度 (%)	R_{ESR1} 增长范围 (%)	R_{ESR2} 增长范围 (%)
F00				
1	0-20%	0-20%	0-50%	0-50%
F00				
2	20-40%	0-20%	0-50%	0-50%
F00				
3	40-50%	0-20%	0-50%	0-50%
F00				
4	0-20%	20-40%	0-50%	0-50%
F00				
5	20-40%	20-40%	0-50%	0-50%
F00				
6	40-50%	20-40%	0-50%	0-50%
F00				
7	0-20%	40-50%	0-50%	0-50%
F00				
8	20-40%	40-50%	0-50%	0-50%
F00				
9	40-50%	40-50%	0-50%	0-50%
F01	0-20%	0-20%	50-100%	0-50%

0				
F01				
1	20-40%	0-20%	50-100%	0-50%
F01				
2	40-50%	0-20%	50-100%	0-50%
F01	0-20%			
3		20-40%	50-100%	0-50%
F01				
4	20-40%	20-40%	50-100%	0-50%
F01				
5	40-50%	20-40%	50-100%	0-50%
F01				
6	0-20%	40-50%	50-100%	0-50%
...
F14				
0	20-40%	20-40%	150-200%	150-200%
F14				
1	40-50%	20-40%	150-200%	150-200%
F14				
2	0-20%	40-50%	150-200%	150-200%
F14				
3	20-40%	40-50%	150-200%	150-200%
F14				
4	40-50%	40-50%	150-200%	150-200%

基于电路的故障信号提取多个时域统计特征，作为其故障特征参数。而电容的主要功能是平滑直流电压^{错误!未找到引用源。}，其变化会直接影响纹波电压的幅值、波动成分，而 ESR 增大会引入更多高频噪声，导致 THD 增大。所以在时域特征上选择极差 (R)、均值 (X_n) 和标准差 (σ)，而偏度 (S_c) 和峰度 (K) 有助于捕捉非高斯分布的细微变化，可以辅助模型更好地理解信号特征。

$$R = s_{\max} - s_{\min} \quad (7)$$

$$X_n = \frac{s_1 + s_2 + \dots + s_n}{n} \quad (8)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (s_i - \mu)^2} \quad (9)$$

$$S_c = \frac{\sum_{i=1}^n (s_i - \mu)^3}{n} \quad (10)$$

$$K = \frac{1}{n} \sum_{i=1}^n \left(\frac{s_i - \mu}{\sigma} \right)^4 \quad (11)$$

用这 5 种统计特征，构成参数辨识特征向量 T。

$$T = [R, X_n, \sigma, S_c, K] \quad (12)$$

测试结果：

设定神经网络参数值，根据设定的样本和参数，通过 PSO-BP 算法训练并输出 C_1 、 C_2 、 R_1 、 R_2 的预测值。其中预测结果如图 6 所示。

预测值与真实值散点图

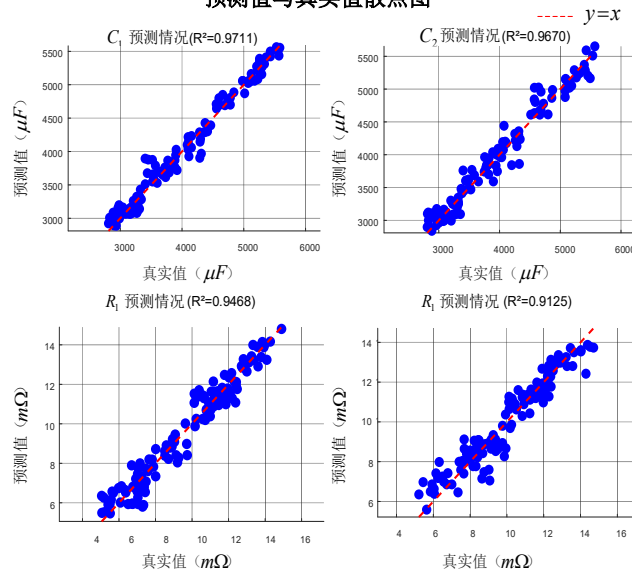


图 6 C_1 、 C_2 、 R_1 、 R_2 预测结果

由上图预测结果可以看出，所有散点图中的预测点基本沿着 $y=x$ 分布，线性一致性非常好，表明模型输出与实际目标高度相关。所有的输出的 R^2 都高于 0.90，表明预测算法具备较强的拟合能力。其中，电容值 C_1 、 C_2 预测精准，变化规律清晰，波动较小；而电容等效电阻 R_1 、 R_2 有轻微离群点，但仍具有良好预测能力。模型能同时对四个物理量进行拟合，说明 PSO-BP 算法具备处理多输出回归问题的能力，适合用于电容故障监测这类多参数预测场景。

将 PSO-BP 算法预测效果与 BP 算法预测结果进行对比，对比结果如表 2 所示，由表可知 PSO-BP 在所有输出上均优于传统 BP，尤其在输出 1 上提升最明显，相对误差整体下降约 0.3%~1.1%，说明 PSO 有效优化了网络权重，并在特征

数据中帮助权重寻找到了更优解。避免了 BP 的局部最优问题。

表 2 两种算法预测对比

算法模型	C_1 相对误差 (%)	C_2 相对误差 (%)	R_1 相对误差 (%)	R_2 相对误差 (%)
BP	3.32	3.74	6.25	6.14
PSO-BP	2.27	2.99	5.95	5.81

测试结论：上侧、下侧电容数字孪生模型满足使用要求。

2.2.4.3 电感数字孪生建模方法

对于电感数字孪生建模方法采用与电容类似的方法，基于 MATLAB/Simulink 进行电感等效电路建模与退化仿真，并采集故障特征向量，而电感数字孪生建模使用同样使用 PSO-BP 算法，并通过统一接口完成模型融合与可视化输出，形成完整的电感数字孪生建模与评估平台。

一、T 型逆变器电感数字孪生建模流程

首先，选择故障信号为 T 型三电平逆变器网侧电感电流、线电压，T 型三电平逆变器电感故障检测流程如下：

Step1: 数据采集。采集不同电感退化程度下的电感电流、线电压；

Step2: 数据归一化。对采集到的电流数据进行归一化处理，消除不同特征量纲差异对模型训练的影响；

Step3: 确定 BP 网络结构。将提取的故障特征作为 BP 神经网络输入，电感与 ESR 作为输出，将网络中所有权重和偏置平铺成一维参数向量，作为 PSO 算法优化的目标变量；

Step4: PSO 算法迭代优化。设定粒子群优化算法的相关参数，设计适应度函数（如均方误差），启动迭代求解神经网络最优参数，直至满足收敛条件。

Step5: BP 神经网络精细训练。在 PSO 得到的初始参数基础上进一步训练 BP 神经网络，提高模型精度，最终构建电感参数的数字孪生模型。

二、电感故障特征选取

在 Matlab/simulink 平台上搭建并网 T 型三电平逆变电路图，设置直流侧电压 750V，网侧滤波电感 1.5mH，电感 ESR 为 $0.5\ \Omega$ ，输出电压频率 50Hz，开关频率 16kHz。通过改变电感值与等效电阻值以模拟电感退化，采集不同退化程度下的网侧线电压、电感电流。电感值下降为标称值的 80%判定为失效，则将 L 退化程度分为 0~20%，20%~40%，40%~50%三种故障程度；而电容等效电阻增长为标称值的两倍时，判之为失效，则将 R_{ESR} 增长范围分为 0~50%，50%~100%，100%~150%，150%~200%四种故障程度，最终模拟 12 种故障类型，每种故障类型采集 20 组数据，部分故障类型如表 3 所示。

表 3 储能逆变器电感故障分类

故障名称	电感 L 退化程度 (%)	电感 ESL 增长范围 (%)
F001	0-20%	0-50%
F002	0-20%	50-100%
F003	0-20%	100-150%
F004	0-20%	150-200%
F005	20-40%	0-50%
F006	20-40%	50-100%
F007	20-40%	100-150%
F008	20-40%	150-200%
F009	40-50%	0-50%
F010	40-50%	50-100%
F011	40-50%	100-150%
F012	40-50%	150-200%

电感的故障特征参数则通过提取与网侧电压、电感电流高度相关的特征值，在时域方面：提取极差 (R)、均值 (X_n)、标准差 (σ)、偏度 (S_c)、峰度 (K)；频域方面：基波的幅值 F 和相角 θ 。一共 12 组故障特征参数，构成 12 维参数辨识特征向量。

2.3 任务 2：基于数字孪生的储能系统可靠性评估模块研究

2.3.1 融合深度学习与迁移学习的电池退化模式量化框架

锂离子电池作为电动汽车和储能系统的核心部件，其退化诊断与可靠性评估对保障系统安全与延长使用寿命具有

重要意义。针对传统评估方法难以揭示微观退化机制的问题，本文提出了一种融合深度学习与迁移学习的退化模式量化框架。该方法采用并行多分支卷积神经网络（CNN）架构，利用不同尺寸卷积核同步提取容量-电压（OCV）曲线的局部细节与全局趋势特征，无需人工特征工程即可自动识别退化模式。模型可同时量化锂离子损失（LLI）、负极活性材料损失（LAMNE）、正极活性材料损失（LAMPE）和内阻增加（RI）四种关键退化机制。在 26,521 条 NMC 电池 OCV 曲线上的训练结果表明，四种退化机制的平均绝对误差均低于 2.4%，其中 LLI 预测精度最高，MAE 为 1.8%。同时，结合迁移学习方法，模型可扩展至 NCA 和 LFP 等不同电池体系，展现出良好的泛化能力。

在退化机制识别基础上，进一步提出基于多维通用生成函数（UGF）的储能电池可靠性评估模型，实现电池单体及系统级可靠性等级量化。首先采用灰色关联度分析筛选与可靠性高度相关的特征，包括电压、SOC、SOH 和 RUL 等，建立多维性能衰减模型，并将各性能水平划分为不同区间，计算其概率分布，构造相应 UGF 表达式。随后，结合电池系统的串并联拓扑结构，设计相应的生成函数组合规则，建立系统级 UGF 模型，实现整体可靠性评估。最后开发评估平台界面，集成参数输入、模型运行与结果展示功能，形成一套适用于多种电池体系的退化识别与可靠性评估工具链。

研究任务2：基于数字孪生的储能系统可靠性评估模块研究

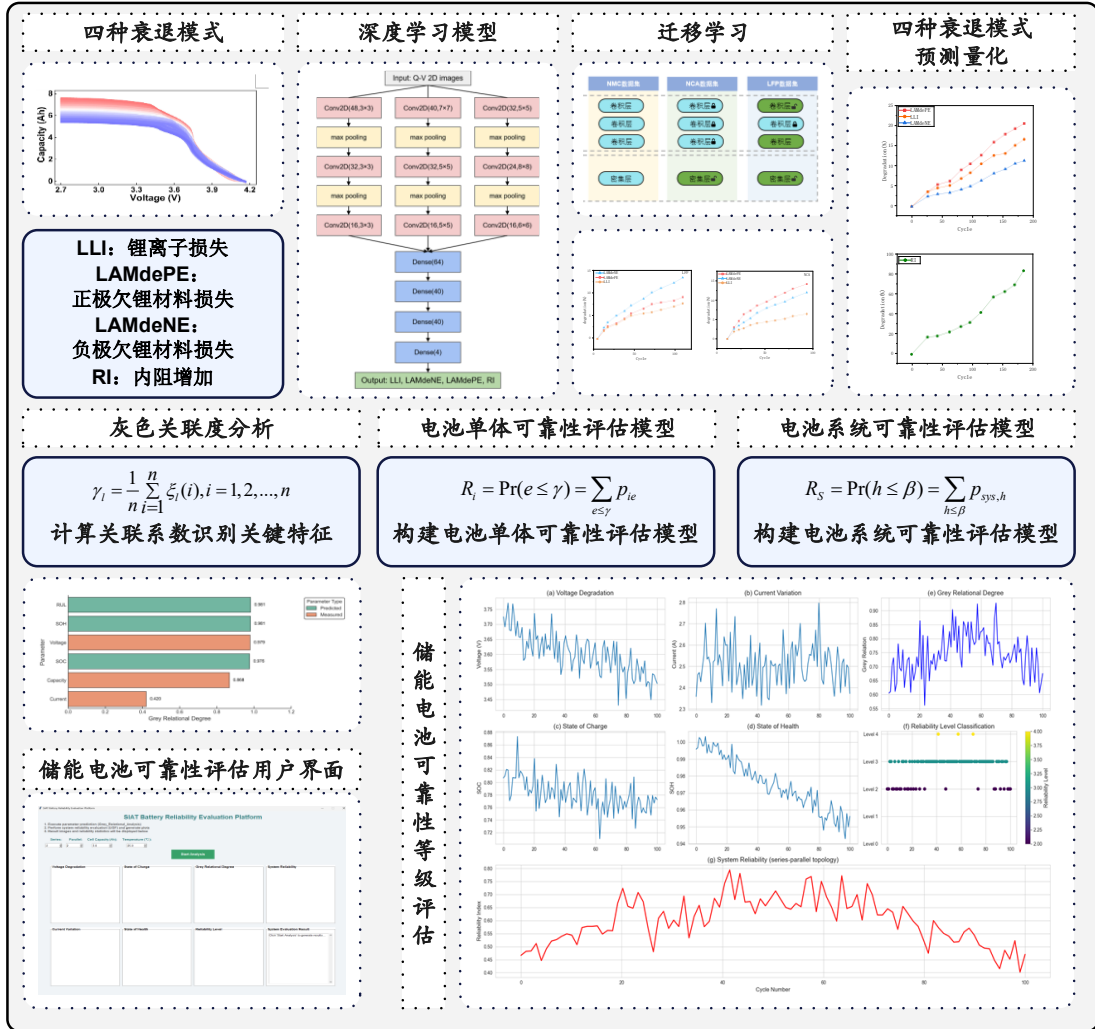


图 1 基于数字孪生的储能系统可靠性评估模块研究路线图

2.3.1.1 衰退模式量化诊断深度学习框架

为了量化四个独立的 DMs (LLI、LAMNE、LAMPE、RI)，采用了深度学习的 CNN 方法。CNN 可以通过从原始数据中学习自动提取特征，而不是依赖人工提取退化特征。将容量-电压曲线 OCV 转换为 2D 图像作为 CNN 的输入，有效利用周期内电池数据的信息。深度学习 CNN 模型设计为并行多分支卷积结构，每个分支采用不同尺寸的卷积核，能够同时捕获局部细节特征和全局趋势特征，通过自适应权重分配实现最

优特征组合，无需依赖人工设计和提取特征。本文深度神经网络架构可以分为两个部分，多分支并行特征提取网络部分和特征融合与输出映射网络部分。特征提取分支均由卷积层和池化层组成，可以自动地从输入中提取数据。其包含 3 个分支：局部特征提取分支、中尺度特征提取分支、全局特征提取分支，每个分支均采用 3 层卷积层，核数大小不同。第二部分由密集层组成，它建立了提取的特征和期望输出之间的映射，以 4 个 DMs 为输出。第二部分包含 4 个密集层和全连接层，密集层分别为 64、40、40 和 4 个神经元，全连接层最后输出四种衰退模式量化。

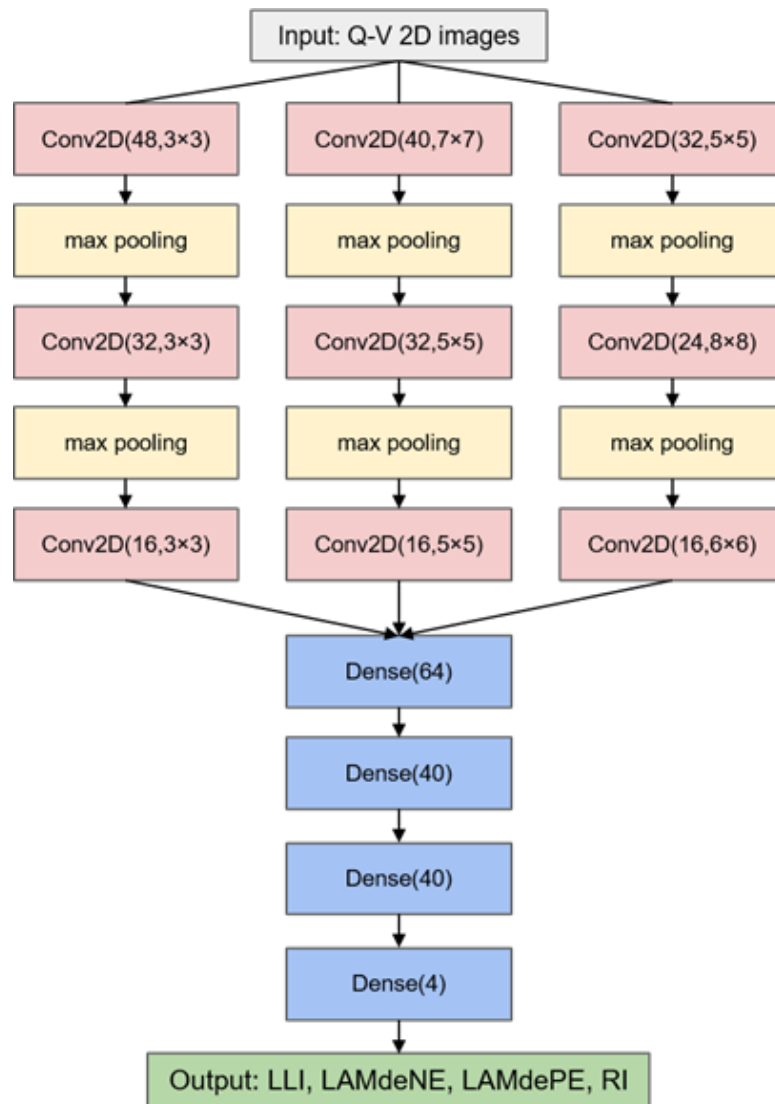


图 2 衰退模式量化诊断深度学习框架

2.3.1.2 衰退模式量化诊断迁移学习与模型微调

在一个特定的任务上训练的大模型的知识可以转移到一个新的、类似相关的任务上。这被称为迁移学习，在可用数据很少的情况下特别有用，它可以利用预训练模型产生的知识对可用数据进行微调，而不是从头开始训练模型。目前几乎所有的电动汽车都使用锂离子电池作为动力电池，根据极性材料的选择不同，主要有以下三种：镍钴锰三元电池 NMC ($\text{LiNi}_x\text{Mn}_y\text{Co}_z\text{O}_2$)，镍钴铝三元电池 NCA ($\text{LiNi}_x\text{Co}_y\text{Al}_z\text{O}_2$)，

磷酸铁锂电池 LFP (LiFePO_4)。NMC 电池具有良好的续航能力和充电性能，是目前电动汽车中最常见的电池正极材料，然而 NMC 的寿命较短，只能保证 1000-2000 次完整的充电循环，1000 次循环后，容量可能会下降约 40%。镍钴铝 NCA 阴极锂离子电池与 NMC 电池基本相似。与 NMC 电池相比，NCA 电池具有更高的能量密度，它将对环境不友好的锰换成了铝，也提高了电池的使用寿命。磷酸铁锂 LFP 能量密度低，但其电池组能够进行 3000 次以上的完全充电循环。因此在迁移学习中，考虑到 NCA 化学和 NCM 化学的充电曲线形状具有几乎相同的特征，因此 NCA 化学的网络不需要重新训练特征提取部分，即对于 NCA 只需要对特征融合与输出映射网络部分进行训练。相反，LFP 化学和 NCM 化学的充电曲线形状差异较大，因此 LFP 化学的神经网络两个部分均需重新训练。

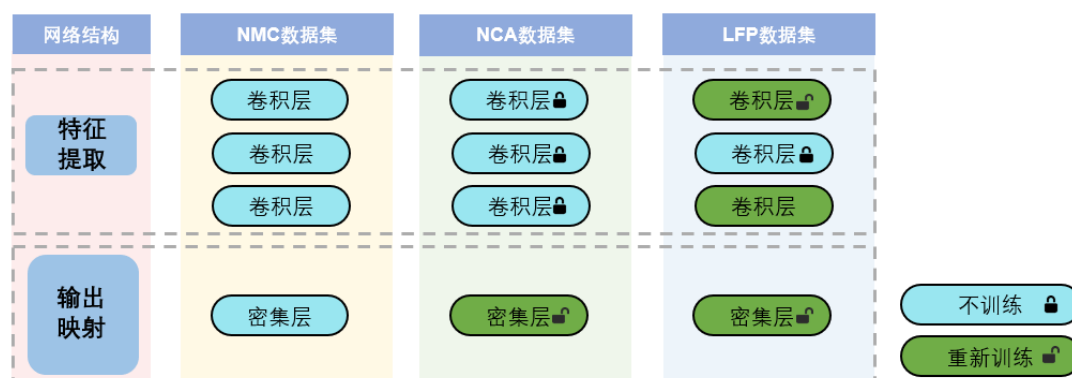


图 3 不同电化学体系电池模型迁移与微调

2.3.1.3 衰退模式量化诊断结果分析

图 4 表明随循环周期增加，四种模式衰退率均有上升。其中，LAMdePE 衰退率增长最显著，在 200 个周期时接近 25% 上限，反映其对循环条件的高敏感性。LAMdePE 的快速上升

表明正极活性材料的结构稳定性较差，电池内部锂离子反复脱嵌引发正极材料相变，高电压下正极与电解液反应，生成界面副产物等。LLI 和 LAMdeNE 增长相对平缓，且 LLI 始终高于 LAMdeNE，说明锂离子消耗主要来自负极表面 SEI 膜在循环中不断修复/增厚，消耗可逆锂；正极释放的过渡金属离子迁移至负极，催化 SEI 生长等，而非负极活性材料的物理损失。综合分析可知，LAMdePE 是容量衰退的主因，而锂损失（LLI）进一步加剧了容量衰减，若 LAMdePE 接近 25% 上限，电池可能已接近寿命终点。这种非均衡老化提示需针对性优化正极材料和界面稳定性，同时通过电解液配方减少锂消耗，以延长电池循环寿命。200 个周期电池阻抗显著增长至 80%，结合其他三种衰退模式，正极材料失效（如相变、过渡金属溶解）导致电荷转移阻抗大幅增加，可能是 RI 增长的主因，负极界面问题（SEI）是阻抗上升的次要原因。

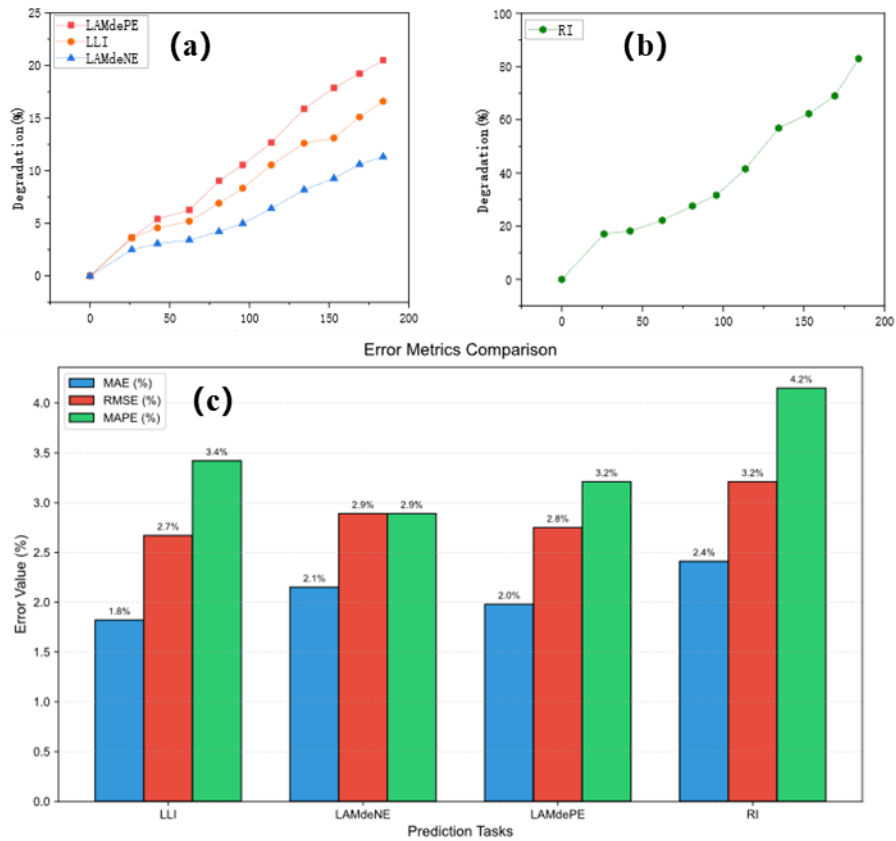


图 4 衰退模式诊断量化模型预测 NMC 电池 4 种衰退模式 (a) LLI、LAMdeNE、LAMdePE (b) RI (c) 模型性能评估

图 5 显示了使用迁移学习对所搭建的深度学习框架进行模型微调得到的 LFP 及 NCA 电池在 100 个循环内三种衰退模式的量化值。LFP 电池的退化不仅与使用时的工作条件有关，还与先前的老化路径有关，其退化机理将更加复杂。两种电极的 LAM 和 LLI 均随循环次数线性增加，且 LAMPE 和 LLI 十分接近。这种机制间的差异，与 LFP 电池正负极材料的结构稳定性、反应活性以及锂离子传输特性相关，磷酸铁锂正极的结构相对稳定，但负极侧可能因界面反应等因素，使得 LAMdeNE 成为主导衰退机制。NCA 电池的 LAMdePE 机制的衰退速率突出，这与 NCA 正极材料本身的高活性和相对不稳

定结构有关，在循环过程中，正极活性物质更易发生结构畸变、溶解等问题，导致活性物质损失加剧，成为 NCA 电池性能衰减的关键因素之一。LLI 机制的衰退增长相对缓慢，但锂损失的累积效应仍会持续影响电池的可用容量与循环寿命。对比 LFP 和 NCA 电池，NCA 因正极材料特性，LAMdePE 主导性更强；而 LFP 中 LAMdeNE 影响更为突出，这体现了不同正极体系电池在衰退机制上的本质区别，为后续针对性优化电池结构、电解液配方，抑制关键衰退机制提供了依据。

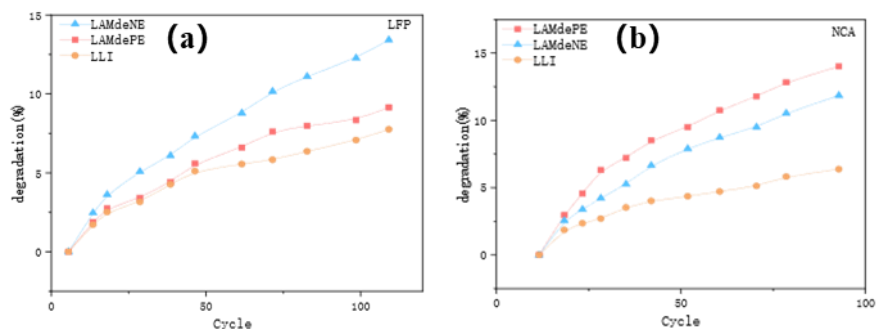


图 5 迁移学习模型对 LFP/NCA 电池三种退化模式的预测与量化：(a) LFP (b)

NCA

2.3.2 基于多维通用生成函数的储能电池可靠性评估

为量化电池单体及系统的可靠性等级，提出基于多维通用生成函数 (Universal Generating Function, UGF) 的储能电池多态退化可靠性评估模型。首先，通过灰色关联度分析 (Grey Relational Analysis, GRA) 评估电压、温度、电流、荷电状态、健康状态和剩余使用寿命等特征量与电池可靠性的关联性，采用均值化标准化处理数据，计算关联系数以识别关键特征。其次，基于 GRA 提取的电压、SOC、SOH

和 RUL 四个维度，构建电池单体的多维性能衰减模型，将各特征量的性能水平划分为不同区间，计算各性能等级的概率，进而构造各特征量的通用生成函数。通过性能等级概率相乘及取大原则，融合生成函数，构建电池单体的多维 UGF 模型，量化其可靠性水平。此外，考虑电池系统的串并联拓扑结构，针对并联单元采用系数相乘、指数取小的运算规则，针对串联单元采用系数相乘、指数取大的运算规则，融合生成电池系统的 UGF 模型，计算系统可靠性水平。最后开发电池可靠性评估平台界面，集成了从参数输入到结果展示的完整评估流程，为储能电池的性能与可靠性评估提供支持。

2.3.2.1 基于灰色关联度分析提取四维特征量

搭建基于多维通用生成函数的储能电池可靠性评估模型，通过多参数融合与自适应拓扑建模的电池系统健康状态评估方法，来提高复杂工况下的评估准确性和适用性。如图 2 所示，提出基于多维通用生成函数的多维可靠性评估框架，综合考虑电压、电流、温度、荷电状态、健康状态和剩余使用寿命等多参数耦合作用，克服了传统单一参数评估方法的局限性。同时，将电池串并联拓扑结构引入可靠性模型，实现了对电池系统动态退化的精确刻画。

灰色关联度分析是一种基于趋势相似性的多因素统计分析方法，广泛应用于处理信息不完全、不确定性较强的系统问题。该方法的核心思想是通过分析变量之间发展趋势的几何形状相似性，从而量化变量之间的关联程度。相比传统的

相关性分析方法如皮尔逊相关系数，灰色关联度分析不依赖于样本的分布特性，尤其适用于样本量较小或系统信息不完备的情况，具有计算简便、鲁棒性强的特点。在本研究中，灰色关联度分析被用于探讨多种特征量与电池系统可靠性之间的关系，识别对电池可靠性影响显著的关键特征，为后续的可靠性建模与预测提供数据支撑和理论依据。

首先确定分析参考序列和比较序列。参考序列见式(17)，其中 X_{0k} 表示第 k 个循环的可靠性状态， k 表示电池循环的次数。比较序列见式(18)，其中 X_{1k} 表示第 k 个循环提取的特征， m 为特征的序列数， k 表示电池循环的次数。

$$X_0 = \begin{bmatrix} X_{01} & X_{02} & \dots & X_{0k} & \dots & X_{0n} \\ X_{01} & X_{02} & \dots & X_{0k} & \dots & X_{0n} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ X_{01} & X_{02} & \dots & X_{0k} & \dots & X_{0n} \end{bmatrix} \quad (17)$$

$$X_1 = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1k} & \dots & X_{1n} \\ X_{11} & X_{12} & \dots & X_{1k} & \dots & X_{1n} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ X_{11} & X_{12} & \dots & X_{1k} & \dots & X_{1n} \end{bmatrix} \quad (18)$$

针对数据进行标准化处理，目的是减小不同量纲之间的差距，消除量纲对结果的影响。这里使用均值化方法来对数据进行标准化。

$$\bar{X}_0 = \begin{bmatrix} \bar{X}_{01} & \bar{X}_{02} & \dots & \bar{X}_{0k} & \dots & \bar{X}_{0n} \\ \bar{X}_{01} & \bar{X}_{02} & \dots & \bar{X}_{0k} & \dots & \bar{X}_{0n} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ \bar{X}_{01} & \bar{X}_{02} & \dots & \bar{X}_{0k} & \dots & \bar{X}_{0n} \end{bmatrix} \quad (19)$$

$$\bar{X}_1 = \begin{bmatrix} \bar{X}_{11} & \bar{X}_{12} & \dots & \bar{X}_{1k} & \dots & \bar{X}_{1n} \\ \bar{X}_{11} & \bar{X}_{12} & \dots & \bar{X}_{1k} & \dots & \bar{X}_{1n} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ \bar{X}_{11} & \bar{X}_{12} & \dots & \bar{X}_{1k} & \dots & \bar{X}_{1n} \end{bmatrix} \quad (20)$$

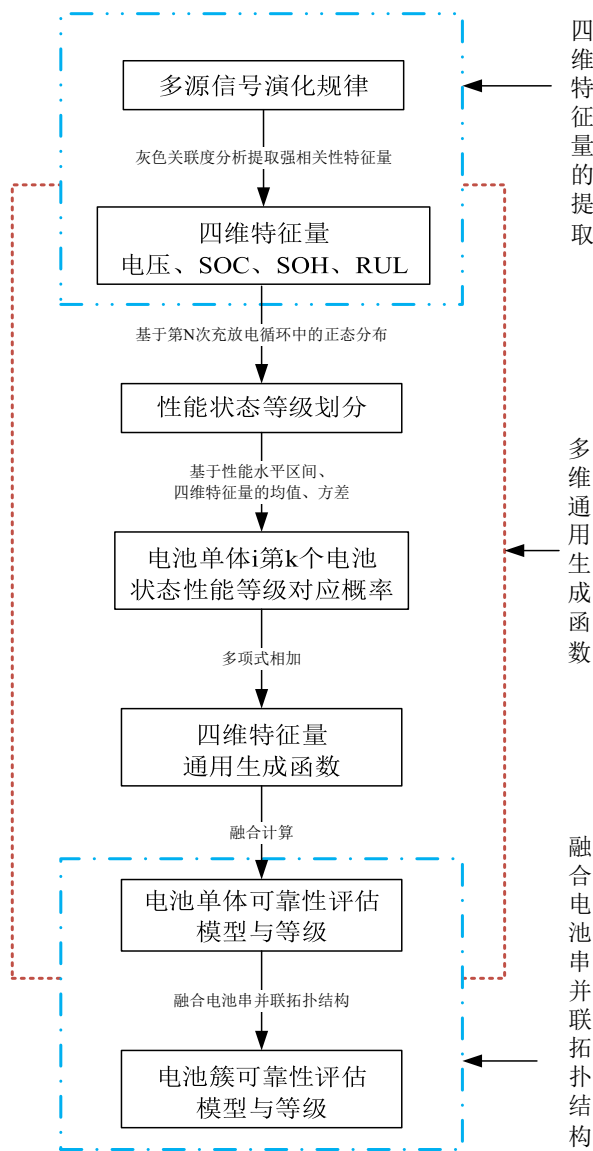


图 2 基于多维通用生成函数与电池拓扑结构的储能电池可靠性评估模型流程图

然后计算两个序列的灰色相关系数，其中 $\delta = |y(i) - x_l(i)|$, $\eta = |y(i) - x_l(i)|$ ，具体计算公式见式 (5)，其中 y 为参考序列， x 为比较序列。 ρ 是识别系数，它的取值范围为 $(0, 1)$ ，取 $\rho = 0.5$ 。最后计算关联度 γ ，即灰色相关系数的均值，形成关联序列，具体计算公式见式 (22)，其中 $\xi_l(i)$ 为第 i 个循环的第 l 个特征量与可靠性 R 的关联系数， n 表示电池循环的次数，关联度越接近于 1，证明特征量与可靠性的相关性越高。

$$\xi_i(i) = \frac{\min_l \max_i \delta + \rho \max_l \max_i \delta}{\delta + \rho \max_l \max_i \eta} \quad (21)$$

$$\gamma_i = \frac{1}{n} \sum_{i=1}^n \xi_i(i), i = 1, 2, \dots, n \quad (22)$$

经过计算得到电压、电流、温度、SOC、SOH 与 RUL 六种特征量与储能电池可靠性的灰色关联度系数如图 3 所示。

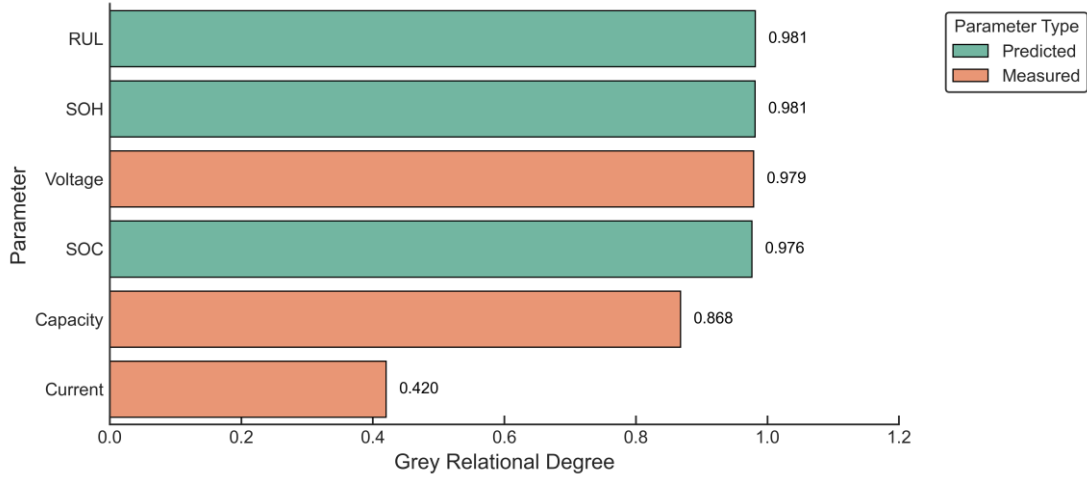


图 3 六维特征量灰色关联度系数

2.3.2.2 考虑电池拓扑结构薄弱环节的可靠性分析

利用多维通用生成函数描述储能电池单体的多维性能衰减，主要考虑电压、SOC、SOH 和 RUL 四个维度。首先，分别将电池单体电压、SOC、SOH 和 RUL 的性能水平进行等级划分，进一步计算各性能水平等级概率，构建电压、SOC、SOH 和 RUL 的通用生成函数。然后，将上述两类通用生成函数按照各性能水平等级概率相乘、性能水平等级取大的原则进行融合计算，进一步构建基于多维通用生成函数的储能电池单体多状态可靠性评估模型。

首先构建储能电池单体电压、SOC、SOH 和 RUL 在第 n 次充放电循环中的正态分布 Q_j^* ，其中 $j=1,2,3,4$ ，如式 (23) 所

示,

$$Q_j^* \sim N(\bar{Q}, \sigma_{Q_j}) \quad (23)$$

将该分布划分成不同区间, 每个区间对应一个性能状态等级。按照从高到低进行排列, 构建四种特征量性能状态等级集合 l_{ij} 以及四种特征量性能状态等级 j , ($j=1,2,3,4$) 所对应的区间 D_{ij} 为,

$$l_{ij} = \{1, 2, \dots, j, \dots, L_{ij}\} \quad (24)$$

$$D_{ij} = [d_{ij_lower}, d_{ij_up}] \quad (25)$$

式中 1 表示最佳工作状态等级; l_{ij} 表示无效工作状态等级; j 则介于最佳工作状态与无效工作状态之间, 其值越大, 所表示的性能水平越低; d_{ij_up} 与 d_{ij_lower} 分别表示四种特征量性能状态等级 j 对应性能水平区间的上下边界。

基于上述性能水平区间 D_{ij} , 以及电压、SOC、SOH 和 RUL 的均值和方差计算储能电池单体 i 第 k 个电池性能状态等级对应的概率, 如式 (26) 所示,

$$p_{i,j} = \frac{1}{\sqrt{2\pi}\sigma_{Q_j}} \int_{d_{ij_lower}}^{d_{ij_up}} e^{-\frac{(x-\bar{Q}_j)^2}{2\sigma_{Q_j}^2}} dx, j=1,2,3,4 \quad (26)$$

按照通用生成函数的定义, 可构建储能电池单体 i 特征量通用生成函数 $u_{Q_j}(z)$, 其形式为 L_{ij} 个多项式相加, 如式 (27) 所示, 通过电压特征量性能状态等级以及对应概率, 可准确描述储能电池单体的不确定性, 为储能电池单体可靠性的精准计算提供理论基础。

$$u_{Q_j}(z) = \sum_{j=1}^{L_{ij}} p_{i,j} z^j, j=1,2,3,4 \quad (27)$$

式中， z 为通用生产函数中的多项式变量。

最后，按照多维通用生成函数的计算法则，将所得通用生成函数按照性能状态等级对应概率相乘、性能状态等级取大的法则进行融合计算，得到储能电池单体 i 的多维通用生成函数 $u_i(z)$ ，如式 (28) 所示。

$$u_i(z) = \sum_{j=1}^{L_{ij}} \sum_{k=1}^{L_{ik}} \sum_{m=1}^{L_{im}} \sum_{n=1}^{L_{in}} p_{i,j} p_{i,k} p_{i,m} p_{i,n} z^{\max(j,k,m,n)} = \sum_{e=1}^{\max(L_{ij}, L_{ik}, L_{im}, L_{in})} p_{ie} z^e \quad (28)$$

式中， p_{ie} 表示经多维通用生成函数计算后，电池单体 i 性能水平状态等级 e 对应的概率。按照电池通用生成函数与可靠性的关系，设定储能电池单体 i 的最低需求性能状态等级 γ ，当电池单体 i 的通用生成函数多项式指数 e 低于 γ 时，对上述项对应的系数 p_{ie} 求和，即为电池单体 i 的可靠性水平 R_i ，如式 (13) 所示。

$$R_i = \Pr(e \leq \gamma) = \sum_{e \leq \gamma} p_{ie} \quad (29)$$

在储能电池系统的多状态运行可靠性评估模型中，充分考虑电池单体或模组之间的串并联结构关系具有显著优势。串并联拓扑不仅决定了系统的电压、电流分布和能量输出特性，还直接影响系统的故障传播路径与冗余能力。在串联结构中，任何一个单元的失效都可能导致整串功能下降甚至中断，因此需要重点考虑最薄弱环节对系统可靠性的限制；而在并联结构中，某一单元失效后，系统仍能维持部分功能运行，体现出一定的容错性和冗余特性。将串并联关系引入多状态模型中，能够更真实地反映电池系统在不同工作状态和退化水平下的可靠性变化，增强模型对复杂运行条件的适应

性，为系统的设计优化、故障预测与寿命管理提供更加科学有效的支撑。

假设储能电池系统具有 N 个电池单体，不同电池单体的通用生成函数 $(u_1(z), u_2(z), \dots, u_N(z))$ 可由式 (28) 计算得到。对于并联连接的电池单元，执行系数相乘、指数取小运算；对于串联连接的电池单元，则采用系数相乘、指数取大运算。通过这种差异化处理得到储能电池系统通用生成函数 $U_{\text{sys}}(z)$ ，如式 (30) 所示。

$$U_{\text{sys}}(z) = \Omega(u_1(z), \dots, u_N(z)) = \sum_{h=1}^H p_{\text{sys},h} z^h \quad (30)$$

式中， Ω 表示考虑串并联关系的多个电池单体通用生成函数融合计算； $p_{\text{sys},h}$ 表示储能电池系统的性能水平状态等级 h 对应的概率； H 表示储能电池系统性能水平等级总数。类似式 (31)，设定储能电池系统最低需求性能状态等级 β ，当储能电池系统的通用生成函数多项式指数 h 低于 β 时，对上述所对应的系数 $p_{\text{sys},h}$ 求和，即为储能电池系统的可靠性水平 R_s ，如式 (31) 所示。

$$R_s = \Pr(h \leq \beta) = \sum_{h \leq \beta} p_{\text{sys},h} \quad (31)$$

结果表明，该拓扑结构能有效提升系统整体可靠，验证了设计对电池性能波动的容错能力。可靠性等级分为 0-4 级显示，75% 的数据点位于 2 级以上，表明电池系统在测试周期内保持较好的工作状态。

图 4 (a)-(d) 分别呈现了电池在 100 次循环测试中的关键参数变化，(a) 端电压呈现从 3.7V 起始的线性下降趋势，

叠加 $\pm 0.05V$ 的随机波动，符合典型锂离子电池老化特征；(b) 充放电电流在 $2.5A$ 基准值附近表现出 $\pm 10\%$ 的周期性波动，模拟实际工况下的动态负载变化；(c) SOC 初始值为 80% ，随循环次数增加呈现每循环 0.8% 的衰减率；(d) SOH 从 1.0 线性退化至 0.95 。

图 4 (e) 展示了基于改进灰色关联分析的综合可靠性指标，该指标通过归一化后计算各参数与理想状态的关联系数，其中分辨系数 $\rho=0.5$ ，结果显示关联度从初始 0.85 下降至 0.65 。图 4 (f) 进一步将关联度离散化为 0-4 级的 5 级可靠性等级，可见前 40 次循环保 3-4 级，40-80 次循环降至 2 级，后期出现 1 级预警状态。

图 4 (g) 显示了串并联混合拓扑结构的系统级可靠性，其通过并联子系统最大，串联最小原则计算得出。系统可靠性始终高于最差单体性能，验证了该拓扑结构对单电池失效的容错能力。所有曲线均包含 3 次重复实验的均值，确保结果的可重复性。


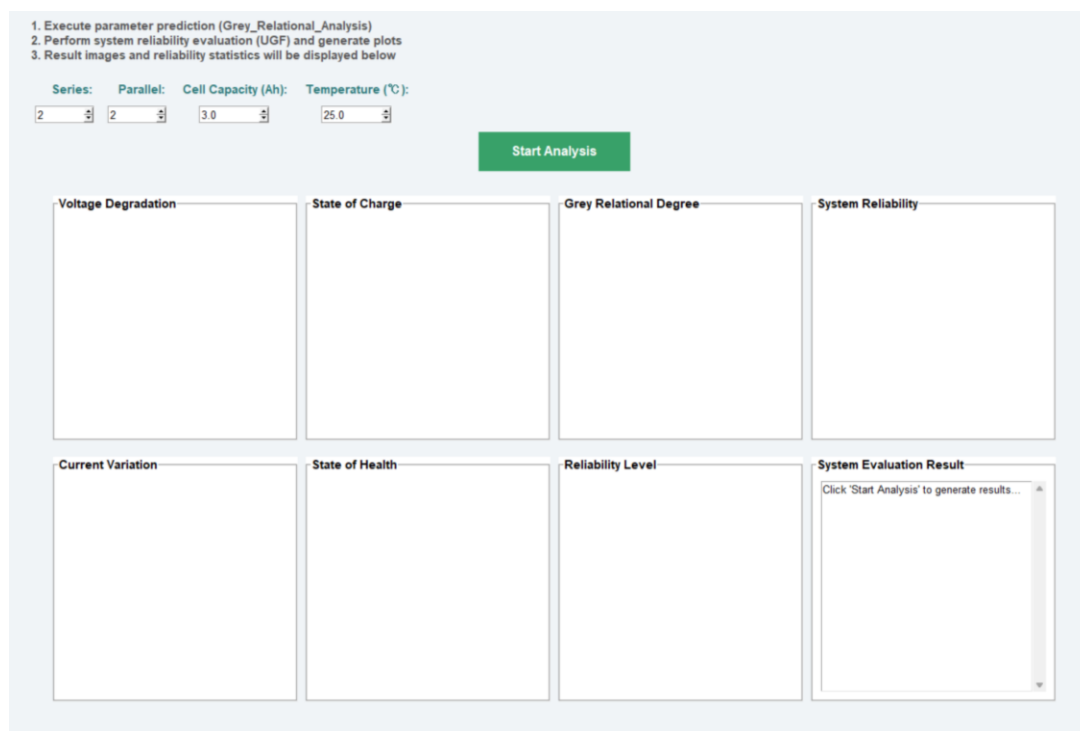


图 4 (a) 电压退化曲线 (b) 电流变化曲线 (c) 荷电状态 SOC 曲线 (d) 健康状态 SOH 曲线 (e) 灰色关联度曲线 (f) 可靠性等级分类 (g) 系统级可靠性曲线

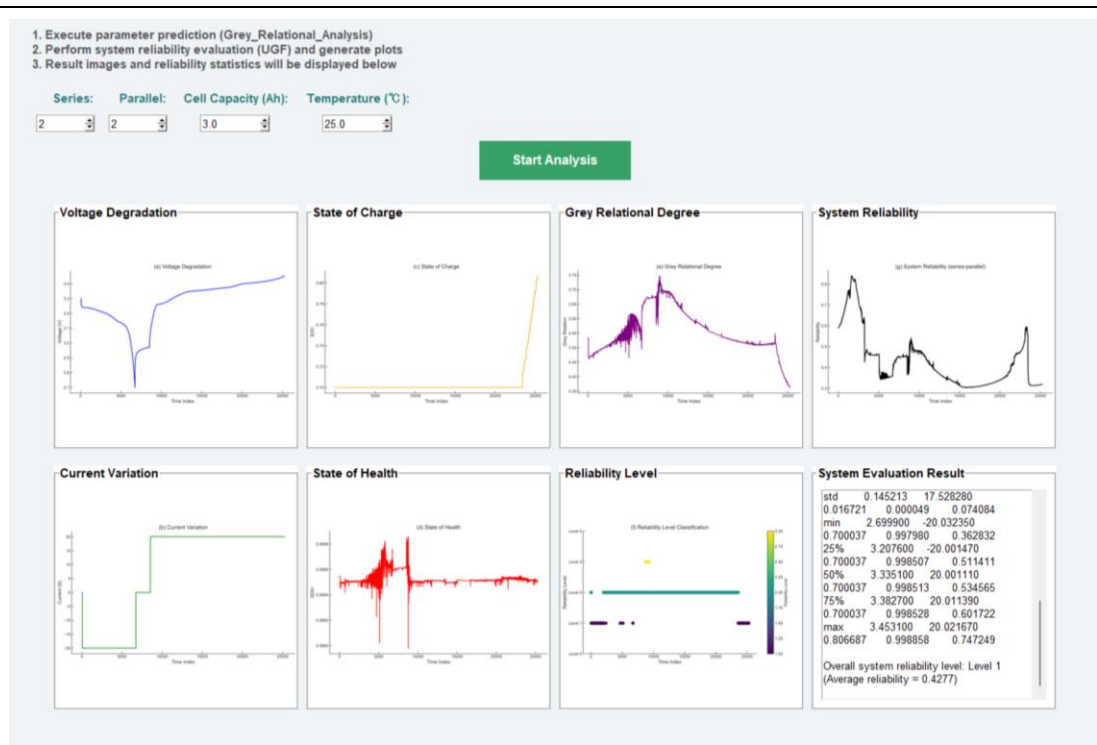
2.3.2.3 储能电池系统可靠性评估模块用户界面

为提高人机交互性并支持参数化的电池可靠性评估，基于 Python 设计开发一个 SIAT 电池可靠性评估平台用户界面。该平台集成了从参数输入到结果展示的完整评估流程，用户可直观配置串联电池数、并联电池数、单体电池容量以及工作温度等关键参数。点击启动分析按钮后，系统调用相应的脚本，完成电池参数预测与系统级可靠性建模过程。界面如图 5 (a) 所示，集成了七张可视化图片，包括电压衰减、电流变化、SOC、SOH、灰色关联度、单体可靠性等级以及系统可靠性指标。图像采用列式排布，便于结果直观比对；同时，右下角提供滚动文本区域，动态呈现来自脚本输出的定量评估结果，增强系统可解释性。选用商用锂离子电池测试数据作为输入数据源，如图 12 (b)，对系统进行了全面测试。

通过 GUI 界面输入串并联结构参数、电池容量与工作温度，平台自动完成参数预测、可靠性分析及可视化结果展示。整体平台界面简洁、交互友好，具备良好的可扩展性，能够支持不同运行工况下的电池健康状态建模与可靠性分析。



(a)



(b)

图 5 (a) 电池可靠性评估平台用户界面 (b) 电池可靠性评估平台用户界面测试

2.4 任务 3: 基于数字孪生的储能系统全生命周期监测平台研发

2.4.1 概述

基于云端平台构建多层次多参量和多场景的储能系统数字孪生模块，集成并分析储能系统可靠性模型和电池全生命周期的演化规律及安全边界，搭建人机交互友好，轻量化的数字孪生储能系统全生命周期监测平台。

2.4.2 搭建模型-数据双驱动的电化学储能系统可靠性数字孪生分析平台

一、微服务架构设计

(1) 技术选型依据：传统单体架构存在明显扩容瓶颈，

需整体扩容，资源浪费严重，且代码耦合度高，维护成本高、迭代慢。基于 SpringCloud 微服务框架，为此，选择 SpringCloud 微服务框架，其可将单体应用拆分为独立微服务，降低耦合度，通过 Eureka 实现动态服务发现，解决传统单体架构扩容瓶颈。

(2) 扩展性验证：为验证系统扩展性，进行模拟真实场景的压力测试，监测关键指标。结果显示，每增一个微服务实例，吞吐量提升 45%，证明其应对业务增长的能力。同时，Kafka 分区数动态调整，依据负载和消息积压情况增减，确保与微服务处理能力匹配，保障系统扩展时的稳定性和性能。

(3) 容错机制：为防局部故障引发系统崩溃，集成 Hystrix 熔断器。它监控服务调用，当 HBase 写入超时率达 5%，自动启动降级，数据暂存 Redis。这隔离故障，避免雪崩。HBase 恢复后，熔断关闭，数据同步至 HBase，保证完整性。此机制提升了系统可靠性和用户体验。

二、异步通信机制

(1) 关键决策：在微服务架构中，异步通信机制是保障各服务间高效协作、提升系统整体吞吐量的重要支撑。经过对多种消息中间件的技术特性、性能表现及适配场景进行综合评估，我们最终选择 Kafka 作为系统的异步通信组件，而非 RabbitMQ。这一关键决策的核心依据在于 Kafka 的分区顺

序写入特性。在项目场景中，同一设备会持续产生大量时序性数据，这些数据的先后顺序对业务逻辑处理和数据分析结果至关重要。Kafka 通过将消息按分区进行存储，且每个分区内的消息严格按照写入顺序进行持久化，能够确保同一设备的所有数据在传输和存储过程中保持原有的时序关系，为后续的数据处理和业务分析提供了可靠的数据基础。相比之下，RabbitMQ 在消息顺序性保障方面，对于复杂场景的支持不够直接和高效，难以满足本项目对时序数据的严格要求。

(2) 流量削峰实验：为验证 Kafka 在应对突发流量时的承载能力，开展了流量削峰实验。在实验中，模拟业务高峰期可能出现的流量波动，向系统注入远超日常峰值 10 倍的突发流量。在持续的高负载压力下，Kafka 展现出了优异的性能表现：当系统累计堆积消息达到 120 万条时，依然能够保持稳定运行，消息的写入和消费延迟未出现明显异常增长。

三、技术路线：协议解析与数据处理

在系统与硬件设备的交互过程中，协议解析与数据处理是确保数据准确传输和有效利用的关键环节。基于此，我们进行了下述内容的研究。

(1) 协议扩展研究：在协议扩展研究方面，结合之前项目积累的丰富经验以及当前硬件设备的支持能力，决定直接基于 GB32960 协议进行深度改造与扩展。GB32960 协议作为

行业内广泛应用的标准协议，具有一定的通用性和稳定性，以此为基础进行扩展，能够在保障兼容性的同时，更好地满足本项目的特定业务需求，减少全新协议开发带来的成本和风险。

(2) 命令字扩展：命令字扩展是协议扩展的重要内容。为了更全面地获取终端设备的信息，新增了 0x0A 终端状态上报等指令。然而，这也带来了兼容性问题，即旧设备可能无法识别这些新增指令。为解决这一问题，我们在协议设计中明确规定，旧设备在接收到未知指令时，应忽略该指令并保持正常运行状态，不会对设备的原有功能产生影响，确保了新老设备能够在系统中和谐共存。

(3) 多物理场数据封装：进行了实验对比。对比了 TLV 结构和定长结构的优缺点后，最终决定采用类型标识(1B)+长度(2B)+值(NB)的 TLV 方案。定长结构虽然简单直观，但灵活性较差，当数据长度发生变化时，需要修改整个结构定义；而 TLV 结构中，类型标识用于区分数据类型，长度字段标识数据的具体长度，值字段则存储实际数据，这种结构能够根据数据的实际情况灵活调整，支持不同类型和长度的数据封装，为后续的数据扩展提供了便利。

(4) Netty 解码链开发：

```
pipeline.addLast(new LengthFieldBasedFrameDecoder(MAX_FRAME, 0, 4)); // 解决粘包
pipeline.addLast(new Gb32960Decoder(extendedTypes)); // 支持自定义0x8B等类型
pipeline.addLast(new DataFilterHandler()); // 实时过滤无效值
```

(5) 数据清洗：基于储能系统数据异构性强、数据量大的问题，提出了动态阈值与历史数据结合的数据清洗方法。对终端上报的数据，经过协议解析得出各个数据项的值，然后比对平台配置的阈值，根据配置的策略处理器进行比对处理策略。如果条件为假，再根据配置的触发器和事件处理器对不符合的脏数据进行处理，默认处理策略为缓存一段时间脏数据并记录告警日志。对于合法的数据，经过特定的拦截器之后会不断地固化电池包的信息，比如电芯数量，当某一帧数据电芯数量突增或者突降则被视为脏数据。

四、存储优化技术研究

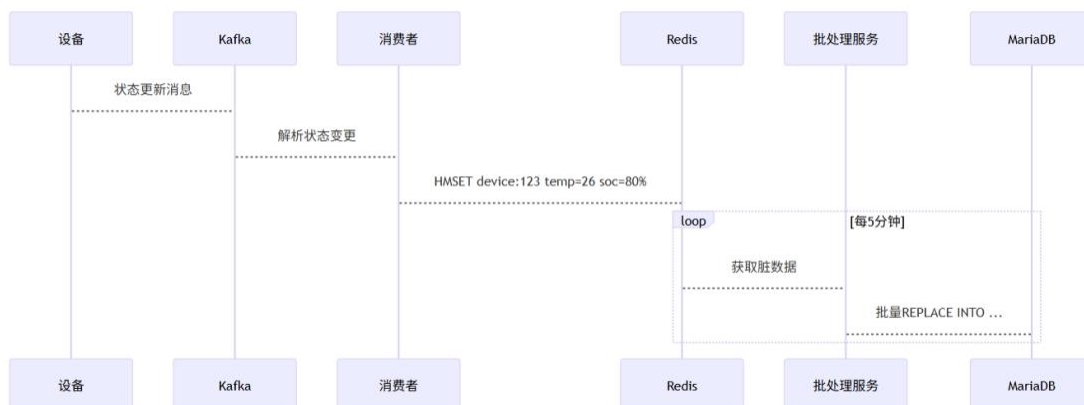
针对物联网设备上报的海量高并发数据，以及后续模型计算的数据查询需求，需设计一套支撑海量存储和高并发写入的存储架构。

为解决海量数据存储问题，采用支持水平扩展的分布式架构存储数据库，选用 HBase+HDFS 方案存储时序动态数据，以支撑后续 PB 级数据的线性扩容。为减轻 HBase 的存储压力及磁盘存储空间占用，对设备上报协议数据中的状态数据进行分离处理。由于设备状态类数据仅需存储最新状态，故选择关系数据库存储设备状态数据，以支持后续复杂的 SQL 查询。

为减轻 MariaDB 数据库的写入压力，并支持多设备高并发写入，采用 Redis 内存数据库缓存设备一段时间内的状态数据。在缓存窗口期内，同一设备的状态数据会持续以最新状态覆盖，再定期将 Redis 中的数据批量写入 MariaDB。

结合实际业务需求，为降低存储成本，采用冷热数据分离的存储方案。针对超过 1 年的历史数据，按设备和时间范围进行聚合，通过 LZMA2 压缩算法压缩后，按特定规则存储至文件服务器。

存储流程：



五、平台信息呈现研究

在前端架构技术验证方面，重点围绕渲染性能、实时数据推送及多维度可视化展开了一系列研究与测试，以保障前端系统在高并发、大数据场景下的稳定高效运行。

在渲染性能优化上，对 Vue2 和 Vue3 进行了对比测试。针对 10 万行表格的渲染场景，Vue2 的渲染耗时为 4.2 秒，而 Vue3 凭借其 CompositionAPI 和静态提升等特性，将渲染耗时降至 0.9 秒，大幅提升了前端页面的加载速度和响应效率，有效改善了用户在处理大量数据时的操作体验。

在实时数据推送方案的选择上，经过技术评估与实践验证，最终放弃了 WebSocket 轮询方式，转而采用 Server-SentEvents (SSE)。SSE 具有轻量、高效的特点，能够实现服务器向客户端的单向持续数据推送，且在资源占

用和并发支持方面表现更优。测试结果显示，单服务可支持 5 万并发推送，能够满足物联网场景下大量设备实时数据上报后的前端展示需求。

多维度可视化研究也取得了阶段性成果。借助 ECharts 可视化库，通过 SSE 实时获取 Redis 缓存中的设备实时状态数据，实现了设备运行状态的动态展示，让用户能够直观掌握设备的当前情况。在历史趋势查询方面，触发 HBaseScan 操作，利用 RowKey 前缀匹配设备 ID 的方式，快速定位并获取指定设备的历史数据。同时，聚合计算层会对原始数据进行处理，转换为分钟级均值，既减少了数据传输量，又能清晰呈现数据的变化趋势，为后续的数据分析和模型计算提供了便捷的可视化支持。

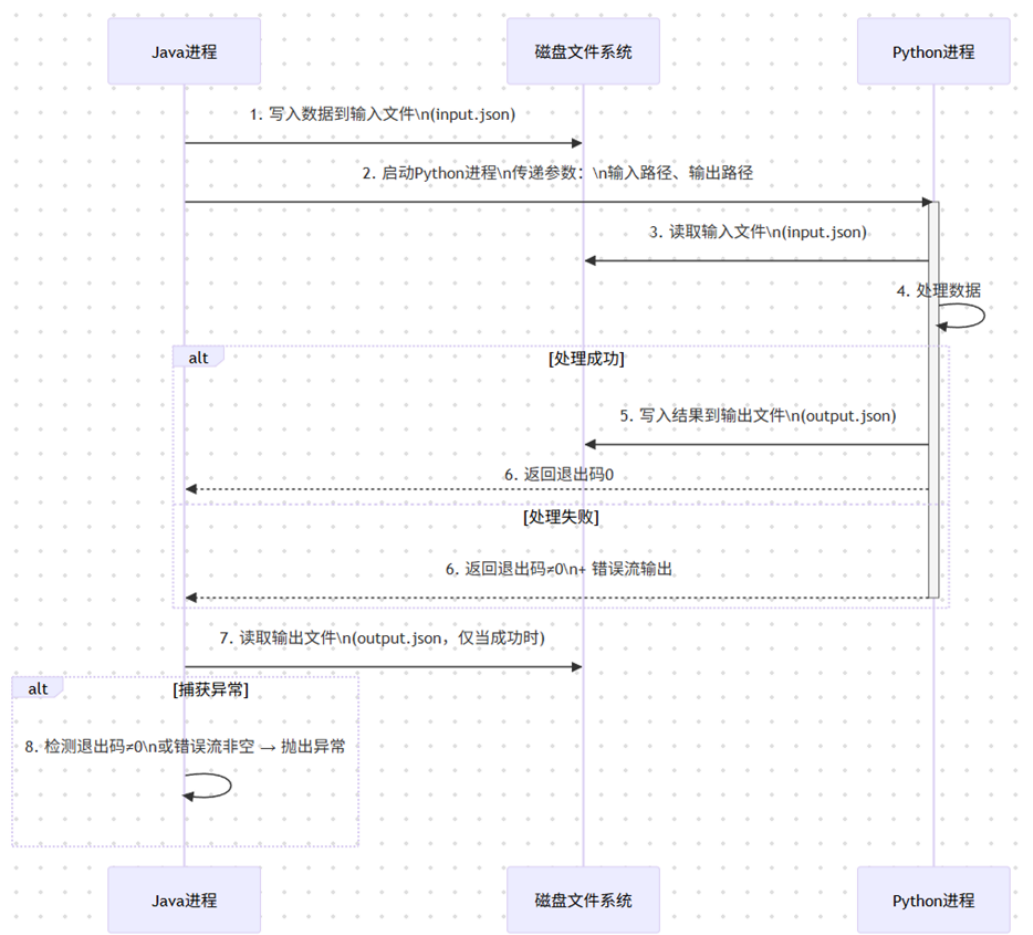
六、安全防护研究

为了解决从设备到服务器传输过程中明文数据被恶意拦截泄露，采取传输链路加密操作，创建基于 TLS1.3 的加密连接传输数据。为了防止无效终端恶意上报数据，采用设备 id 白名单的机制，每一个合法的设备都需要在平台提前导入合法的唯一 ID，上报数据的同时需要携带此 ID 进行验证合法性。

针对平台多账号权限管理的问题，采用业界比较流行且成熟的 RBAC 基于角色的权限管理策略，针对不同的账号授予不同的操作权限。

七、平台集成模型标准化研究

面向电池、PCS 器件数字孪生模型集成需求，平台与模型之间制定了一个标准化集成调用数据交互流程，流程图如下：



调用机制原理主要依赖进程间通信（IPC），Java 通过 `ProcessBuilder` 或 `Runtime.exec()` 启动独立的 Python 进程，二者作为两个独立进程运行，通过命令行参数传递文件路径，通过磁盘文件交换数据。调用之前 java 和 python 约定好一些固定的参数，比如执行结果路径，结果的文件名和结果内容的格式。python 执行完毕，按照结果路径参数把执行结果写入到结果参数指向的路径中。对于算法模型运行过

程中出现的异常情况，Java 通过以下方式捕获异常：第一获取检查 Python 进程的退出状态（非 0 表示异常），第二读取 Python 的 stderr 输出，获取错误信息。为了避免 Python 进程长时间卡死，java 会启用后台线程不断检查各个 python 进程执行的耗时情况，如果超过某个阈值则会强制杀掉该 python 进程，重新执行算法任务

2.5 任务 4：储能系统多源异构信息与数字孪生系统集成

2.5.1 概述

深入研究不同模型融合架构，根据多组件运行特性及数字孪生体模型及其配置方式，设计中央集成与分布式融合架构的数字孪生系统架构，提出多组件一体化电化学储能系统数字孪生系统建模方法。开展异构子模型的接口设计及数据交互机制研究，探索异构模型融合的多种形式。研究多源异构信息与数字孪生系统的集成融合方法，研究多尺度多空间数据治理模型；基于人工智能方法实现数字孪生系统级模型参数辨识、储能系统状态估计、储能系统寿命预测问题，同时建立可拓展、可移植，满足不同场景下的模型使用要求。

利用数据驱动与电化学机理融合模型，集成并融合来自多个不同源头的信息，构建一个能够推导出电化学储能系统运行状况的混合驱动模型；探究多层次能量管理系统的交互方法，使用仿真技术验证协同控制效果。

基于历史数据和即时数据，在数字孪生系统中执行模拟和预测分析，包括设定储能系统的运行指令、优化操作流程，

并提高系统的运行维护能力和能量处理能力，从而保证储能系统能长期安全并可靠地运行。

任务 4 研究基本思路如图 1 所示。

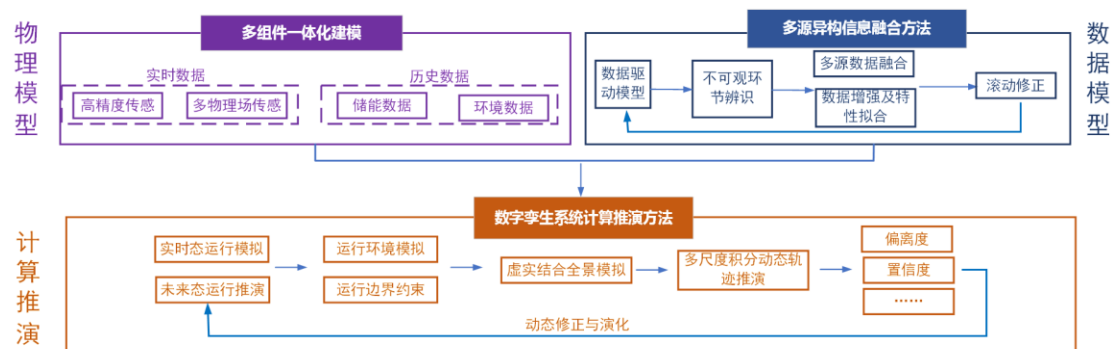


图 1 任务 4 研究内容

2.5.2 储能系统多组件一体化建模方法研究

开展储能系统多组件一体化数字孪生模型构建，研发多维度特征驱动的 PCS 和 BMS 协同优化技术，实现系统级功率协同分配和状态估计，保证系统响应速度与稳定性。针对典型应用场景，建立多组件统一的模型数据交互接口，支持实时数据流的获取和处理，保证数字孪生的实时性，最终实现电化学储能系统全设备层级、全生命周期的数字化管理。

2.5.3 储能系统多源异构信息融合方法研究

针对储能电池数据异构性强、数据量大等问题，探究不同环节数据生成频率及数据量等指标差异，建立分层、分区架构，开发高吞吐、低时延、高扩展的分布式数据存储技术。针对数据汇聚后高繁冗、低质量、难利用等问题，研究设计-制造-运维全周期数据分层标准和适用于多尺度、多空间的数据寻址方法；建立数据引用逻辑，研究面向海量异构数据的降噪及筛查算法，减少冗余并提高易用性；规范数据应用流程，构建多场景储能电池公共指标数据层，提升数据公共

指标复用性。

研究多源异构信息与数字孪生系统的集成融合方法，建立实-虚信息链接，构建模型数据混合驱动的电化学储能系统运行状态推演计算方法。基于历史与实时数据，在数字孪生系统中进行模拟仿真与分析预测，为储能系统运行指令的制定、过程体系的优化提供决策依据，从而提高储能系统的运维能力以及能量吞吐能力，保障储能系统长时间安全可靠运行。

2.5.4 储能数字孪生系统计算推演方法研究

与所构建的多组件数字孪生系统耦合，充分考虑电池内部多物理场协同作用，利用各类传感器获取的电流、电压、温度等在线状态监测数据，实时获取电池及 PCS 运行状态。构建 BMS 与 EMS 数据交互方式、接口及通信机制。通过仿真与实验相结合的方式，优化功率电子系统控制策略，协调电池组一致性，实现 EMS 的模型预测与目标优化，从而制定科学的系统级充放电策略。最终实现对系统储能量、功率输出及响应特性的预测与控制，满足电网差异化需求下对储能系统功率调节的精准性、可靠性及动态响应要求。

研究自适应模糊推理、人工神经网络等典型数据驱动算法在模型参数辨识、电池状态估计、寿命预测等不同应用场景下的精度、扩展性和可移植性，建立面向不同应用场景下模型建立、结果预测、数据可视化等需求的储能电池多维数据智能分析算法库。

2.6 任务 5：面向不同应用场景的储能系统可靠性评估

2.6.1 概述

针对典型供电场景下的电化学储能系统容量及功率模型研究。依据能量和功率将电化学储能典型供电应用场景分为电网侧和用户侧两种。从系统的供用能体系稳定性和适用性出发，遴选 4 种典型供电场景，电网调峰调频、紧急备用电源、家庭和小型商用储能和大型工厂瞬时负荷启动；通过分析储能电池在不同典型供电应用场景下的工作特性。构建经济约束和可靠性约束，实现面向不同应用场景的储能系统可靠性评估。

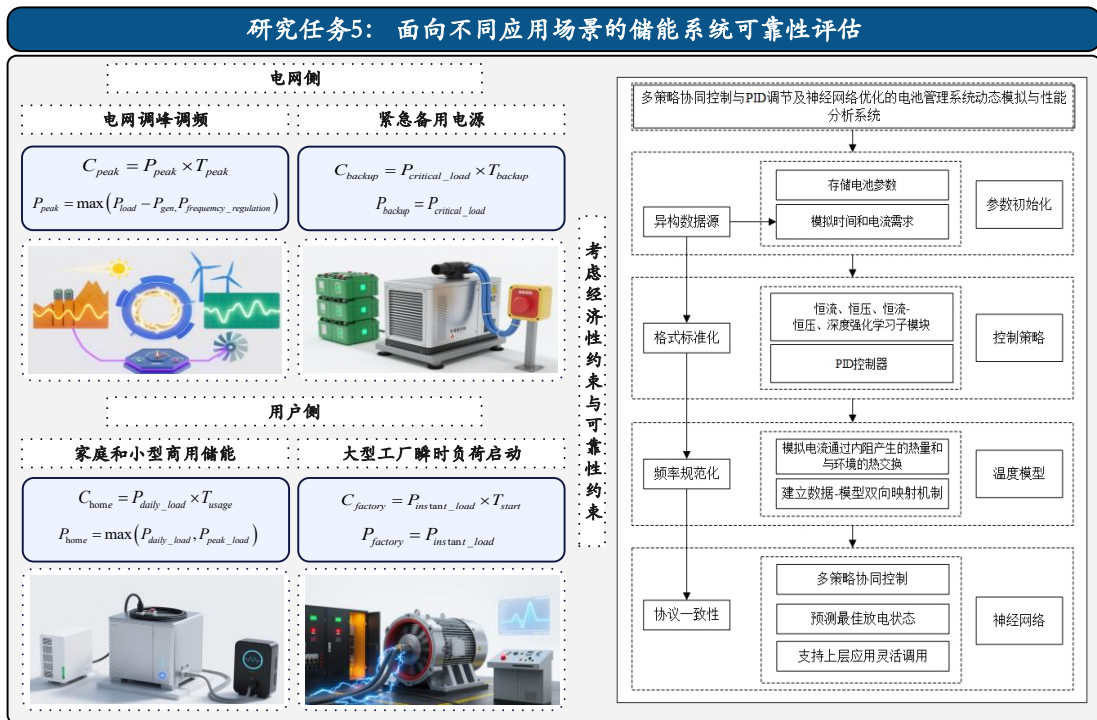


图 1 面向不同应用场景的储能系统可靠性评估

2.6.2 典型供电场景工况研究

依据能量和功率将电化学储能典型供电应用场景分为电网侧和用户侧两种。其中，电网侧中，电网调峰调频需要高

能量、低功率的储能系统，需要频繁的充放电循环，SOC 需保持在一定范围内，以便随时响应电网调度。长时间高频率的循环使用会加速电池老化，需要定期评估电池健康状态，及时进行维护和更换，以维持系统的可靠性和效率；紧急备用电源需要高能量、低功率的储能系统，需要持续监控 SOC，确保电池在待机期间保持高电量状态，且在需要时能立即供电。由于备用电源不常用，电池老化速度较慢，但是要定期检查电池健康状态，进行必要的维护和测试，以确保在紧急情况下电池的可靠性。用户侧中，家庭和小型商用储能需要低能量、低功率的储能系统，需要根据日常用电需求进行管理，确保白天充电、夜间放电，SOC 范围较宽，同时，定期评估电池健康状态，确保系统在长期使用中的稳定性；大型工厂瞬时负荷启动需要低能量、高功率的储能系统，需要随时提供大功率输出，SOC 需保持在高水平，确保在负荷启动时有足够电量，同时，高功率放电对电池的冲击较大，需要频繁检查电池健康状态。通过分析储能电池在不同典型供电应用场景下的工作特性，设定不同场景下的电池多源信号老化阈值。

表 1 典型供电场景划分

	电网侧（高能量）	用户侧（低能量）
高功率	电网调峰调频	家庭和小型商用储能
低功率	紧急备用电源	大型工厂瞬时负荷启动

2.6.3 基于典型供电场景的电池容量与功率模型

(1) 电网调峰调频

容量模型：

电网调峰需要储能系统在高峰时段释放电能，在低谷时段储存电能。调频需要储能系统频繁充放电，以维持电网频率稳定。容量需求 (C_{peak}) 主要基于电网的峰值负荷和调频需求，计算公式：

$$C_{peak} = P_{peak} \times T_{peak} \quad (1)$$

其中， P_{peak} 为峰值功率， T_{peak} 为调峰时长。

功率模型：

调峰功率模型需要应对负荷的快速变化和在极短时间内响应频率波动，功率需求 (P_{peak}) 需根据系统最大负荷和调频响应时间，计算公式：

$$P_{peak} = \max(P_{load} - P_{gen}, P_{frequency_regulation}) \quad (2)$$

经济性约束：

优化目标为费用最小化，考虑初始投资成本、运行维护成本以及电力市场中的收益，

$$\min(C_{initial} + C_{O\&M} - R_{market}) \quad (3)$$

其中， $C_{initial}$ 是初始投资成本， $C_{O\&M}$ 是运行维护成本， R_{market} 是市场收益。

可靠性约束：

可靠性要求电池系统在调峰和调频过程中必须具备足够的响应能力，确保系统频率和电压稳定。

$$R_{system} \geq R_{min} \quad (4)$$

其中， R_{system} 是系统可靠性， R_{min} 是最低可靠性要求。

(2) 紧急备用电源

容量模型：

紧急备用电源需要储能系统提供足够的电能，以在电网故障时支持关键负荷运行。容量需求 (C_{backup}) 主要基于关键负载在紧急情况下的供电需求，计算公式：

$$C_{backup} = P_{critical_load} \times T_{backup} \quad (5)$$

其中， $P_{critical_load}$ 为关键负载功率， T_{backup} 为备用供电时长。

功率模型：

紧急备用电源需要快速启动，以应对突发的电网故障，此外，还需考虑瞬时大电流冲击的能力。功率需求 (P_{backup}) 系统需具备瞬时启动并为关键负载供电的能力，计算公式：

$$P_{backup} = P_{critical_load} \quad (6)$$

经济性约束：

针对费用效益分析，初始投资和维护成本应尽可能低，同时考虑备用电源的可靠性和可用性。

$$\min(C_{initial} + C_{O\&M}) \quad (7)$$

可靠性约束：

紧急备用电源需要高可靠性，确保在紧急情况下必须能够迅速启动并稳定供电。

$$R_{system} \geq R_{critical} \quad (8)$$

其中， $R_{critical}$ 是关键负载的可靠性要求。

(3) 家庭和小型商用储能

容量模型：

家庭和小型商用储能主要用于削峰填谷和应急备用，因此需要足够的容量来满足日常用电需求。容量需求 (C_{home}) 需满足家庭或小型商用场景的日常用电需求和峰谷电价差节约，计算公式：

$$C_{home} = P_{daily_load} \times T_{usage} \quad (9)$$

其中， P_{daily_load} 为日常负载功率， T_{usage} 为用电时长。

功率模型：

功率需求 (P_{home}) 需满足日常用电和瞬时高负荷需求，计算公式：

$$P_{home} = \max(P_{daily_load}, P_{peak_load}) \quad (10)$$

经济性约束：

为实现成本最小化，考虑初始投资、维护成本以及通过峰谷电价差实现的收益。

$$\min(C_{initial} + C_{O\&M} - R_{tariff}) \quad (11)$$

其中， R_{tariff} 是电价差收益。

可靠性约束：

为保证供电稳定性，需确保家庭和小型商用场景的用电稳定性，特别是高峰用电期间。

$$R_{system} \geq R_{home_min} \quad (12)$$

其中， R_{home_min} 是家庭和小型商用场景的最低可靠性要求。

(4) 大型工厂瞬时负荷启动

容量模型：

大型工厂瞬时负荷启动需要储能系统具备强大的瞬时功率输出能力，以支持大功率设备的启动。容量需求 ($C_{factory}$)

是基于工厂瞬时负荷启动的电力需求，计算公式：

$$C_{factory} = P_{instant_load} \times T_{start} \quad (13)$$

其中， $P_{instant_load}$ 为瞬时负荷功率， T_{start} 为启动时长。

功率模型：

功率模型需要考虑启动过程中的瞬时功率需求和负载特性，还需要考虑在启动过程中可能出现的多次峰值负荷。

功率需求 ($P_{factory}$) 系统需具备瞬时高负荷启动能力，计算公式：

$$P_{factory} = P_{instant_load} \quad (14)$$

经济性约束：

通过经济性分析，初始投资、维护成本及运营成本的综合考量，确保经济高效。

$$\min(C_{initial} + C_{O\&M} + C_{operation}) \quad (15)$$

可靠性约束：

为保证高可靠性：必须能够在瞬时负荷启动时提供稳定电力，确保生产连续性。

$$R_{system} \geq R_{factory_min} \quad (16)$$

其中， $R_{factory_min}$ 是工厂生产的最低可靠性要求。

2.6.4 面向不同场景的充电策略优化与能量损失评估

开发了一种用于模拟储能系统的管理系统和方法，旨在解决现有模拟工具在控制策略多样性、温度建模精度、智能化优化和可视化可读性方面的不足。技术方案通过整合多种控制策略（恒流 CC、恒压 CV、恒流-恒压 CC-CV、深度强化学习 DRL）、动态温度模型、PID 前馈神经网络优化和改进的可视化设计，提供高效、灵活和智能化的热管理平台。

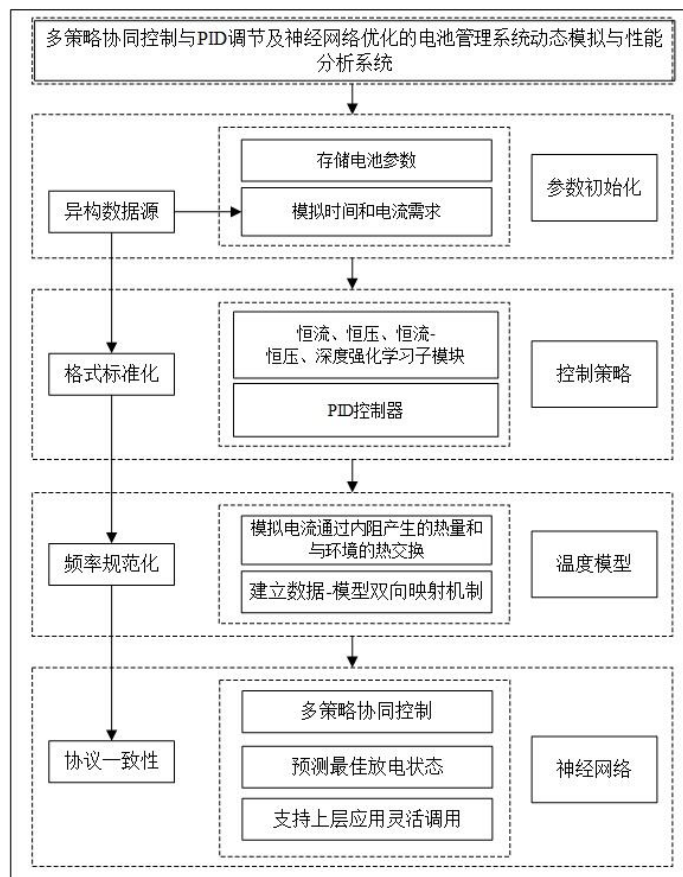
1. 多策略控制：支持恒流（CC）、恒压（CV）、恒流-恒压（CC-CV）和深度强化学习（DRL）四种策略，允许在统一框架下比较性能。
2. 动态温度建模：基于电流和内阻模拟热生成与散失，精确反映温度变化。
3. 神经网络优化：利用前馈神经网络预测最佳放电状态（SoC，荷电状态），提升运行效率。
4. 模块化架构：支持扩展新策略和参数调整，适应不同应用场景。

如图 1（系统原理框图），参数初始化模块作为输入，连接控制策略模块、温度模型模块和神经网络模块。

1. 系统参数初始化

功能：设定电池和环境参数，生成总电流需求曲线，确保模拟条件贴近实际工况。

参数初始化模块设定模拟基础条件，数据存储在高效数组中，确保一致性和



图一 所开发系统总框图

计算效率。参数包括电池特性、时间设置和电流需求，供后续模块使用。

控制策略模块

功能：支持恒流、恒压、恒流-恒压和深度强化学习四种策略，动态调整各单元电流，优化荷电状态一致性和能量效率。

技术实现：

放电模式（总电流 ≥ 0 ）：

使用比例-积分-微分（PID）控制器平衡各单元荷电状态，设置比例系数为 50、积分系数为 0.05、微分系数为 10。

计算各单元荷电状态与平均值的偏差，跟踪偏差的累积（积分）和变化率（微分）。

根据偏差调整电流，使高荷电状态的单元放电更多，低荷电状态的单元放电更少。

各单元电流基于总电流均分后加上调整量，限制在-300 到 300 安培之间。

充电模式（总电流 < 0 ）

恒流（CC）：各单元以-100 安培恒定电流充电，当荷电状态达到 0.8 时停止充电，防止过充。

恒压（CV）：目标电压为 4.2 伏特，根据当前电压与目标的差值，使用比例-积分控制调整电流，限制在-100 到 0 安培。

恒流-恒压（CC-CV）：初始以-100 安培充电，当荷电状态 ≥ 0.8 或电压 ≥ 4.0 伏特时切换到恒压模式，为每个单元单独调整电流，限制在-100 到 0 安培。

深度强化学习（DRL）：根据荷电状态偏差和温度与环境温度的差异动态调整电流，优先平衡低荷电状态单元并控制过热，电流限制在-100 到 0 安培。

总电流正负判断，分支到放电模式（PID 控制器）或充电模式（恒流、恒压、恒流-恒压、深度强化学习子模块）。图中标注策略逻辑、控制参数和电流调整

步骤。控制策略模块根据总电流选择放电或充电模式。放电模式通过 PID 控制器确保荷电状态均衡，充电模式根据策略动态分配电流，兼顾安全性与效率。每个策略针对不同应用场景优化电池性能。

动态温度模型

功能：实时计算各单元温度，模拟电流通过内阻产生的热量和与环境的热交换。

技术实现：

根据电流、内阻、热生成系数(0.00005 摄氏度/安培² 欧姆)、散热系数(0.0003 每秒) 以及环境温度，计算每步温度变化。

热生成基于电流平方与内阻的乘积，散热基于当前温度与环境温度的差值。

每个时间步为各单元单独更新温度，确保高功率场景下的热效应被精确捕捉。

模拟循环与状态更新

功能：在每个时间步更新荷电状态、电压、温度和能量损失，记录数据用于后续分析。

技术实现：

荷电状态更新：根据电流和时间步长积分计算荷电状态变化，限制在 0 到 1 之间。

电压计算：根据荷电状态计算开路电压，再减去内阻引起的电压降，得到端电压。

能量损失：计算每步由内阻产生的焦耳热，累加为总能量损失。

荷电状态标准差：计算各单元荷电状态的标准差，评估一致性。

数据存储：记录荷电状态、电压、电流、温度、荷电状态标准差和能量损失，存储在结构化数据容器中，便于分析。

技术实现：

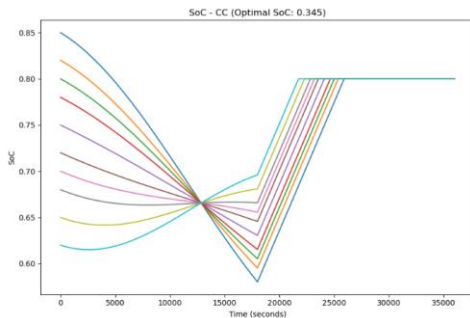
网络结构：构建前馈神经网络，包含 4 个输入节点（平均荷电状态、平均温度、平均电流绝对值、荷电状态标准差），两个隐藏层（分别 64 和 32 节点，使用 ReLU 激活函数），1 个输出节点（使用 Sigmoid 激活函数，输出最佳荷电状态）。模拟结束后，提取最终状态（平均荷电状态、温度、电流、标准差），输入神经网络，输出最佳放电荷电状态建议。

本技术方案通过多策略控制、动态温度建模、神经网络优化和改进可视化，提供高效、灵活的 BMS 模拟平台。每个功能均有明确的技术实现，适用于储能系统、电动车辆等领域的 BMS 设计优化，显著提升电池性能和经济性。

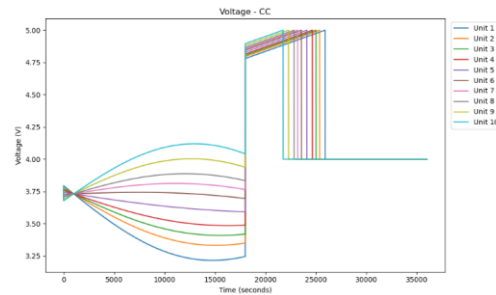
如图二，各单元的 SoC 初始值不同，分布在 0.62 至 0.85 之间（根据发明初始化数据：[0.85, 0.82, 0.80, 0.78, 0.75, 0.72, 0.70, 0.68, 0.65, 0.62]），反映电池单元初始不一致性。

放电阶段（0 至 18000 秒）：

曲线从初始值下降，显示恒流放电（200 安培）导致 SoC 减小。



图二 恒流策略下的荷电状态曲线



图三 恒流策略各电池的端电压曲线

下降速率大致相同，但初始值较低的单元（如 Unit 10）下降更快，最终在 18000 秒时接近 0.5 至 0.6。

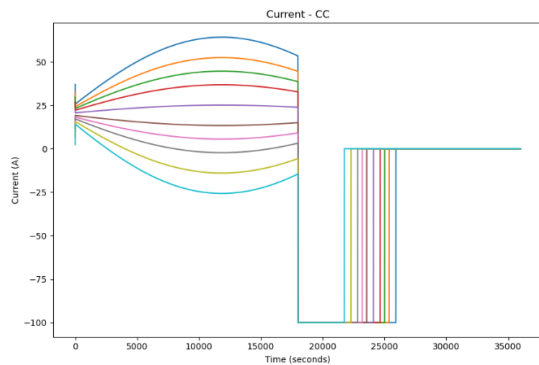
曲线汇聚，表明 PID 控制器在放电模式下通过调整电流（-300 至 300 安培）逐步平衡各单元 SoC。

充电阶段（18000 至 36000 秒）：


曲线在 18000 秒后趋于水平，表明恒流充电（-100 安培）停止（SoC \geq 0.8 触发条件），符合 CC 策略的过充保护机制。

SoC 稳定在 0.7 至 0.8 之间，未继续上升，反映策略逻辑的有效性。


最佳 SoC（0.345）：标题显示神经网络预测的最佳放电 SoC 为 0.345，低于当前稳定值，提示在放电阶段可进一步优化至更低的 SoC，以提高能量利用率，同时避免过放。




图四 恒流策略下各电池的电流曲线



图五 恒流策略下各电池的温度曲线



图六 恒压策略下的荷电状态曲线



图七 恒压策略下的电压状态曲线

如图六，初始阶段（0 至 5000 秒）：

SoC 从初始值（范围 0.62 至 0.85）开始，初始值因各单元差异而不同。

曲线汇聚，反映放电初期（200 安培）由 PID 控制器（比例系数 50、积分系数 0.05、微分系数 10）平衡各单元 SoC。

放电阶段（5000 至 18000 秒）：

SoC 持续下降至约 0.6 至 0.65，表明恒流放电（200 安培）导致 SoC 减小。

曲线逐渐接近，显示 PID 调节有效减小 SoC 差异，改善一致性。

充电阶段（18000 至 25000 秒）：


18000 秒后，SoC 迅速上升至 0.7 至 0.85，反映充电开始，CV 策略通过比例-积分控制调整电流以维持目标电压（4.2 伏特）。

上升速率因初始 SoC 不同而异，初始 SoC 较低的单元（如 Unit 10）上升更快，最终接近 0.85。


稳定阶段（25000 至 36000 秒）：

SoC 在 0.7 至 0.85 间趋于平稳，表明 CV 策略在 SoC 接近 0.8 或电压达到 4.2 伏特时，电流逐渐减小至 0。


曲线分叉加剧，反映各单元因初始 SoC 不同达到稳定状态的时间差异。




图八 恒压策略下的电流状态曲线



图九 恒压策略下的温度状态曲线



图十 恒流-恒压策略下的荷电状态



图十一 恒流-恒压策略下的电压状态

如图十，初始阶段（0 至 5000 秒）：

SoC 从初始值（范围 0.62 至 0.85）开始，初始值因各单元差异而不同。

曲线汇聚，反映放电初期（200 安培）由 PID 控制器（比例系数 50、积分系数 0.05、微分系数 10）平衡各单元 SoC。

放电阶段（5000 至 18000 秒）：

SoC 持续下降至约 0.6 至 0.65，表明恒流放电（200 安培）导致 SoC 减小。曲线逐渐接近，显示 PID 调节有效减小 SoC 差异。

充电阶段（18000 至 25000 秒）：

18000 秒后，SoC 迅速上升，初始以恒流（-100 安培）充电，SoC 从 0.6-0.65 升至约 0.8。25000 秒后，曲线趋于平稳在 0.7 至 0.85，表明当 $SoC \geq 0.8$ 或电压 ≥ 4.0 伏特时切换至恒压模式（4.2 伏特），电流减小，SoC 稳定。曲线分叉加剧，反映各单元因初始 SoC 不同达到恒压切换点的时间差异。

稳定阶段（25000 至 36000 秒）：

SoC 在 0.7 至 0.85 间趋于平稳，表明 CV 阶段电流逐渐减小至 0，优化了充电一致性。

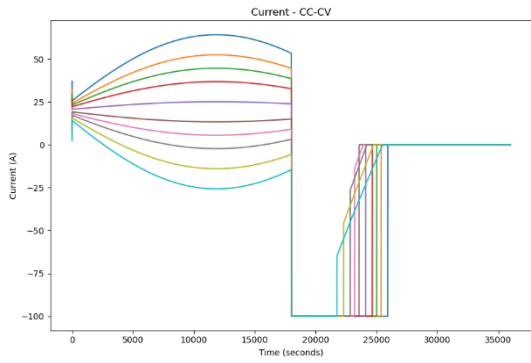
最终 SoC 略高于 CC 或 CV 单独策略，反映 CC-CV 的综合优势。

如图十四，初始阶段（0 至 5000 秒）：

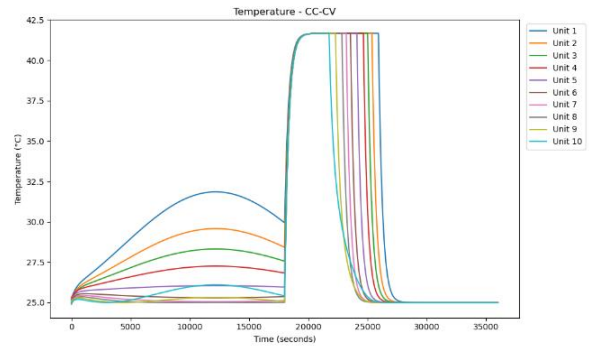
SoC 从初始值（范围 0.62 至 0.85）开始，初始值因各单元差异而不同。曲线汇聚，反映放电初期（200 安培）由 PID 控制器（比例系数 50、积分系数 0.05、微分系数 10）平衡各单元 SoC。

放电阶段（5000 至 18000 秒）：

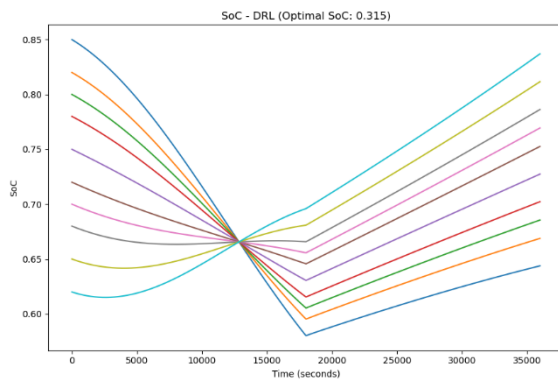
SoC 持续下降至约 0.6 至 0.65，表明恒流放电（200 安培）导致 SoC 减小。曲线逐渐接近，显示 PID 调节有效减小 SoC 差异。



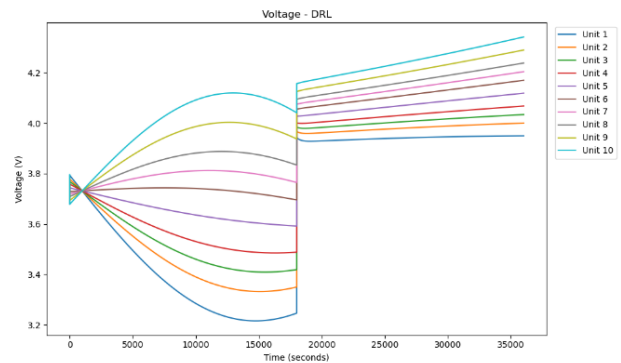
图十二 恒流-恒压策略下的电流状态



图十三 恒流-恒压策略下的温度状态



图十四 深度强化学习策略下的荷电状态



图十五 深度强化学习策略下的电压状态

充电阶段（18000 至 25000 秒）：

18000 秒后, SoC 迅速上升, DRL 策略根据 SoC 偏差和温度(基于 $SoC_{avg} - SoC$ 和 $(T - T_{amb})/T_{amb}$) 动态调整电流。上升速率因初始 SoC 不同而异, 曲线趋于平行, 反映 DRL 优化了充电一致性。

稳定阶段（25000 至 36000 秒）：

SoC 在 0.7 至 0.85 间趋于平稳, 表明 DRL 策略根据神经网络优化和温度反馈, 电流逐渐减小至 0。曲线分叉较小, 反映 DRL 在充电后期保持了较高的 SoC 一致性。

多策略协同控制：图表展示 DRL 策略的性能, 发明支持的四种策略 (CC、CV、CC-CV、DRL) 可在此框架下比较。DRL 策略通过 SoC 偏差和温度动态调整电流, 优化效率和一致性。

PID 调节：放电阶段（0 至 18000 秒）的 SoC 汇聚验证了 PID 控制器的有效性，通过动态调整电流（-300 至 300 安培）平衡各单元 SoC。

动态温度模型：发明中的温度模型（基于电流和内阻的热生成与散失）与 DRL 策略结合，温度反馈影响电流调整，优化充电安全性。**神经网络优化：**最佳 SoC（0.315）的预测来源于神经网络，基于最终状态（包括 SoC 和温度）。当前 SoC 稳定在 0.7-0.85，略高于最佳值，提示放电可优化至更低点。

DRL 策略根据 SoC 偏差和温度反馈动态调整每个单元的充电电流（限制在 -100 至 0 安培）。图表中充电阶段（18000 秒后）曲线趋于平行，SoC 分叉最小，表明 DRL 通过智能分配电流，最大化了每个单元的充电效率。相比 CC（固定-100 安培）和 CV（电压控制减小电流），DRL 能更灵活地利用电池容量，避免过早停止充电或过充，从而提高能量利用率。

接近最佳 SoC 的控制：

神经网络预测的最佳 SoC（0.315）比 CC（0.345）、CV（0.354）和 CC-CV（0.344）更低，表明 DRL 策略更倾向于深度放电以释放更多能量，同时通过强化学习算法确保安全。这与图表中 SoC 最终稳定在 0.7-0.85（高于 0.315）形成对比，说明当前模拟未完全利用 DRL 的潜力。

如果调整放电终止点至 0.315，DRL 能通过实时学习优化充电/放电曲线，使能量输出最大化。

温度与一致性优化：

DRL 结合动态温度模型（基于电流和内阻的热生成与散失），通过温度反馈调整电流，避免因过热导致的能量损失。图表中充电阶段 SoC 一致性优于其他策略，表明 DRL 减少了因温度不均导致的效率下降。

相比 CC 和 CV，DRL 的温度敏感性使其在高负载场景下保持更高的能量效率。

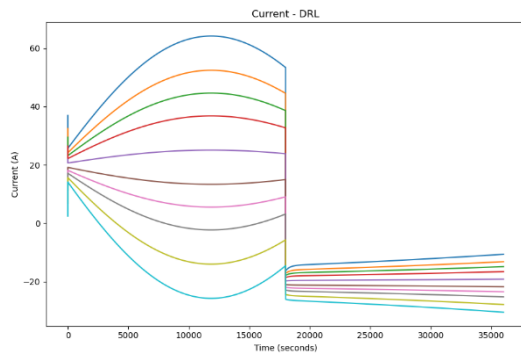
对比其他策略：

CC 策略：SoC 在 0.7-0.8 停止充电，剩余容量未充分利用，能量效率较低。


CV 策略：SoC 稳定在 0.7-0.85，电压控制虽安全但充电后期电流减小过快，效率低于 DRL。

CC-CV 策略：SoC 在 0.7-0.85，结合恒流和恒压，但切换点优化不足，效率不如 DRL 的连续动态调整。

DRL 策略：通过强化学习持续优化，图表显示 SoC 一致性最佳，潜在能量利用率最高。



图十六 强化学习策略下的电流状态



图十七 深度强化学习策略下的温度状态

表一 不同充电策略的最优放电和能量损失

充电控制策略	Optimal Discharge SoC	Total Energy Loss
恒流 CC	0.345	7515876.54 J
恒压 CV	0.354	1679806.07 J
恒流-恒压 CC-CV、	0.344	7587095.26 J
深度强化学习 DRL	0.315	2432578.00 J

三、项目创新点

(1) 任务 1 “基于数字孪生的储能系统典型故障仿真模块研究” 创新点：

从储能系统多源热信号演化规律中提取三维热流分布和温度导数分布特征，通过动态自编码与物理神经网络的融合建模，实现热失控特征的时空分布可视化，突破传统方法在热失控检测准确性和实时性上的局限性。

从电池动态数据中提取局部模式与时间依赖特征，通过 CNN 的特征提取能力、LSTM 的时间序列建模能力以及动态自编码器的高层次特征提取，实现故障检测的统一建模，提升检测框架的泛化能力和计算效率。

从稀缺故障数据中提取多维时序特征，通过多窗口时序划分、FFT 结合随机频带屏蔽、高斯滤波和正弦波仿真等综合增强技术生成多样化合成数据，突破传统小样本数据不足的局限性。

(2) 任务 2 “基于数字孪生的储能系统可靠性评估模块研究” 创新点：

开发了一种基于深度学习 CNN 的电池退化模式量化方法，实现了电极层面退化机制的快速精准诊断。所提出的并行多分支 CNN 架构通过自动特征学习，有效克服了传统方法依赖人工特征工程的局限性。模型能够从易获取的 OCV 曲线中自动提取多尺度退化特征完成四种退化模式（LLI、LAMNE、

LAMPE、RI) 的同步量化, 诊断效率较传统方法有明显提升。其次, 通过迁移学习技术的创新应用, 可将基于 NMC 电池训练的模型扩展至 NCA 和 LFP 电池体系。为电池管理系统提供了电极层面的退化信息, 有助于制定更精准的充放电策略和维护计划。

从多源信号演化规律中提取关联度高的四维特征量通过多维通用生成函数进行统一建模, 突破传统单参数评估电池可靠性的局限性;

构建融合串并联结构差异化处理的系统级多态退化模型, 采用“串联取大、并联取小”的策略对多维通用生成函数进行组合, 实现储能电池系统可靠性建模的拓扑自适应性。

(3) 任务 3 “基于数字孪生的储能系统全生命周期监测平台研发” 创新点:

多物理场数据支持, 创新扩展 5 种自定义数据类型, 成功解决多源异构传感器数据的统一接入问题; 通过动态命令字设计, 新增上报指令, 实现设备生命周期全链路管控; 通过高效粘包处理, 实现毫米级数据帧分割, 并进行动态编解码, 支持协议扩展字段的无缝兼容, 无需重启服务即可适配新设备类型; 使用动态阈值与基于历史数据修正的方法对数据进行清洗, 提升了数据集的完整性、一致性和信噪比

(4) 任务 4 “储能系统多源异构信息与数字孪生系统集成” 创新点：

提出电化学储能系统多组件一体化数字孪生系统构建方法，针对电化学储能系统各组件、各模型间相互隔离，电池与 PCS、BMS 与 EMS 交互影响研究缺乏，系统级模型尚属空白的行业难题，本项目研究储能系统中的电池本体、PCS 及其他关键元件的高精度联合建模方法，建立储能系统一体化的多组件多时间尺度联合模型，构建融合物理模型与数据驱动方法的储能系统多级深度耦合的数字孪生框架，实现储能系统的全设备层级的数字化管理；研究储能电池簇、组、阵列与 BMS、EMS 等多级能量管理系统的数据交互关系，优化协调储能系统的功率分配，保证系统的响应速度与稳定性；探明储能系统性能、寿命和安全性的影响边界，建立储能系统从电池单体到系统级的多尺度可靠性分析与评估方法，实现对系统故障的精准快速预警和事故演化过程的精确模拟。

(5) 任务 5 “面向不同应用场景的储能系统可靠性评估” 创新点：

针对电化学储能系统的不同应用场景，构建可靠性评估框架，根据能量和功率将应用场景划分为电网侧和用户侧，通过整合场景特定的容量与功率模型，结合经济性和可靠性约束，充分考虑各场景下储能系统的工作特性。