
分类号: TM912

单位代码: 10363

密 级: 公开

学 号: 2220320118

**题 目 基于部分充电数据的锂电池健康状态
快速检测**

**题 目 Rapid detection of the state of health of
lithium batteries based on partial charging data**

学 生 姓 名: 李旗帜

校 内 导 师: 陈其工教授

校 外 导 师: 陈任峰老师

专 业 (领 域) : 电子信息(控制工程)

研究方向(领域): 锂电池健康状态检测

论 文 答 辩 日 期: 2025 年 05 月 11 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：

李维中

日期：2025 年 5 月 15 日

安徽工程大学学位论文版权使用授权书


学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 _____ 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：



指导教师签名：



日期： 2025 年 5 月 15 日

日期： 2025 年 5 月 15 日

基于部分充电数据的锂电池健康状态快速检测

摘 要

锂电池健康状态（State of Health, SOH）的快速精准检测是当前该领域面临的关键技术难题之一。针对传统方法存在的全周期充放电数据依赖性强、模型参数优化效率低、检测时间长（通常 ≥ 3 小时）等问题，本研究提出基于部分充电数据，并且使用融合容量增量分析（Incremental Capacity Analysis, ICA）与蜣螂算法优化 BP 神经网络的快速检测锂电池 SOH 的方法。

首先，研究通过系统的实验揭示出锂电池在充放电过程的电压-容量规律特性：充电初期（0-10% SOC，State of Charge，电池荷电状态）与后期（90-100% SOC）的电压变化受极化效应干扰显著，而在充电的中期（20-80% SOC），相关参数呈现更为平缓且稳定的变化趋势。基于此发现，创新性地构建 ICA 特征提取与 DBO-BP 神经网络协同的混合建模框架：1、通过微分处理恒流充电阶段的电压-容量曲线，提取容量增量（ dQ/dV ）曲线的峰值特征作为健康因子；2、采用 Savitzky-Golay 滤波器进行数据降噪，解决原始数据离散性导致的特征提取误差；3、使用 DBO 算法来优化 BP 神经网络的初始权重和阈值，这样可以解决传统神经网络很容易掉进局部最优这个问题。

实验采用马里兰大学 CALCE 锂电池公开数据集（CS2_35 至 CS2_38）进行验证，结果表明：DBO 优化提升了 BP 神经网络的超

参数收敛速度，模型决定系数 R^2 从优化前的 0.9475-0.9538 提升至 0.9629-0.9779，均方误差 MSE 降低 46.31% 至 0.000763 水平。进一步通过时域特征分析发现，仅需采集初始充电阶段前 30 分钟的电压-电流时序数据，即可实现 SOH 的高精度估算。相较于传统全周期检测方法，数据需求量减少 83%，检测时间从 3 小时缩短至 0.5 小时，且关键指标保持率显著：在测试中，MAE（平均绝对误差）稳定在 0.0161-0.0193 区间，RMSE（均方根误差） ≤ 0.0401 。

本研究在方法层面实现三重创新突破：其一，首次将 DBO 算法应用于锂电池 SOH 估算领域，通过模拟蜣螂滚球、繁殖等生物行为建立动态参数优化机制，使神经网络权值调整效率提升 35%；其二，创建 ICA-DBO-BP 多模态融合架构，将容量增量曲线的物理可解释性与智能算法的非线性拟合能力相结合；其三，提出基于短时域充电数据的检测范式，突破传统方法对完整充放电周期的数据依赖，为锂电池的 SOH 快速检测提供新技术路径。

关键词：锂电池，健康状态评估，蜣螂优化算法，容量增量分析，短时域检测，快速检测

Rapid detection of the state of health of lithium batteries based on partial charging data

ABSTRACT

The rapid and accurate assessment of the State of Health (SOH) of lithium-ion batteries represents a critical technical challenge in current research endeavors within this field. To address the limitations of traditional methods, including their heavy reliance on full-cycle charge-discharge data, low efficiency in model parameter optimization, and prolonged detection time (typically ≥ 3 hours), this study proposes a novel approach for fast SOH estimation. The method is based on partial charging data and integrates Incremental Capacity Analysis (ICA) with the Dung Beetle Optimization (DBO) algorithm to optimize the Backpropagation (BP) neural network.

Through systematic experiments, this research elucidates the voltage-capacity characteristics of lithium batteries during charge-discharge cycles. Key findings reveal that voltage variations in the initial (0-10% SOC, State of Charge) and final (90-100% SOC) charging phases are significantly affected by polarization effects, while the middle of the charging phase (20-80% SOC), the relevant parameters exhibit a

smoother and more stable variation trend. Building on this discovery, an innovative hybrid modeling framework synergizing ICA feature extraction with a DBO-optimized Backpropagation (BP) neural network is constructed. The methodology involves three pivotal advancements: 1. ICA Feature Engineering: Differentiation of voltage-capacity curves during constant-current charging enables extraction of peak features from incremental capacity (dQ/dV) curves as health indicators. 2. Data Denoising: Implementation of Savitzky-Golay filtering mitigates feature extraction errors caused by raw data discreteness. 3. DBO-Driven Neural Optimization: Introduction of the DBO algorithm to refine initial weights and thresholds of the BP network, effectively alleviating local optima traps inherent in traditional neural networks.

Validation experiments utilizing the University of Maryland CALCE lithium battery dataset (CS2_35 to CS2_38) demonstrate significant improvements: DBO optimization accelerates hyperparameter convergence by 40%, elevates the coefficient of determination (R^2) from 0.9475 – 0.9538 to 0.9629 – 0.9779, and reduces mean squared error (MSE) by 46.31% to 0.000763. Time-domain analysis further reveals that SOH can be accurately estimated using only 30-minute voltage-current temporal data from the initial charging phase. Compared to conventional

full-cycle methods, this approach reduces data requirements by 83%, slashes detection time from 3 hours to 0.5 hours, and maintains robust performance metrics: mean absolute error (MAE) stabilizes at 0.0161 – 0.0193, with root mean square error (RMSE) ≤ 0.0401 in cyclic tests.

This study achieves three groundbreaking innovations:

1.First Application of DBO in Battery SOH Estimation: By simulating bio-inspired behaviors including dung beetle ball rolling and breeding, a dynamic parameter optimization mechanism enhances neural network weight adjustment efficiency by 35%.

2.ICA-DBO-BP Multimodal Fusion: Integrating the physical interpretability of incremental capacity curves with the nonlinear fitting capabilities of intelligent algorithms.

3.Short-time horizon detection paradigm: This paradigm eliminates the dependence on the full charge-discharge cycle and pioneers real-time health monitoring of power batteries. It provides a new technical path for the rapid detection of SOH in lithium batteries.

Li Qi Zhi(Electronic Information)

Supervised by Professor Chen Qi Gong

KEY WORDS: Lithium-ion batteries, State of Health estimation, Dung Beetle Optimization algorithm, Incremental Capacity Analysis, Short-time horizon detection, Rapid detection

目录

摘 要	I
ABSTRACT	III
第 1 章 绪论	1
1.1 本课题的研究背景及意义	1
1.1.1 研究背景	1
1.1.2 研究意义	2
1.2 国内外研究现状	3
1.2.1 国外研究现状	4
1.2.2 国内研究现状	5
1.3 本文研究内容	6
第 2 章 锂电池工作原理及 SOH 估算方法	8
2.1 锂电池基本构造与工作原理	8
2.2 锂电池老化机理	9
2.2.1 正负极材料老化	10
2.2.2 固态电解质膜老化	10
2.2.3 电解液老化	10
2.2.4 电极/电解质界面老化	10
2.2.5 其它因素	11
2.3 锂电池 SOH 的估算方法	11
2.3.1 基于物理特性的估算方法	11
2.3.2 基于物理模型的估算方法	12
2.3.3 基于算法分析数据的估算方法	13
2.4 现有研究的局限性	14
2.5 本章小结	15
第 3 章 锂电池基本性能实验	16

3.1 实验背景	16
3.2 实验平台搭建	16
3.2.1 实验电池	16
3.2.2 高精度可编程充放电设备	18
3.2.3 实验条件	19
3.2.4 实验评价指标	19
3.3 不同放电倍率下的锂电池放电容量实验	20
3.3.1 实验步骤	20
3.3.2 实验结果	21
3.4 不同充电倍率下的锂电池放电容量实验	23
3.4.1 实验步骤	23
3.4.2 实验结果	24
3.5 HPPC 实验	27
3.5.1 实验步骤	27
3.5.2 实验结果	28
3.6 本章小结	30
第 4 章 基于 DBO 优化 BP 神经网络的 SOH 估算	32
4.1 前言	32
4.2 实验数据介绍	32
4.3 介绍容量增量方法	33
4.4 介绍 BP 神经网络	34
4.5 介绍蛭螂优化算法	36
4.6 蛭螂优化算法优化 BP 神经网络	37
4.7 基于 DBO 优化 BP 神经网络的 SOH 估算结果	38
4.8 本章小结	42
第 5 章 基于部分充电数据的锂电池 SOH 快速估算	43
5.1 前言	43
5.2 分析容量增量曲线和数据采集时间的关系	43
5.3 基于 CALCE 部分充电数据 SOH 估算	44

5.4 本章小结	47
第 6 章 总结与展望	48
6.1 全文总结	48
6.2 工作展望	48
参考文献	49
攻读学位期间发表的学术论文目录	56
致谢	57

第 1 章 绪论

1.1 本课题的研究背景及意义

1.1.1 研究背景

全球对环境保护问题、以及能源可持续发展问题的关注度不断提高，中国亦快速的响应国际号召，提出相对应的“双碳”政策，为实现 2030 年碳达峰与 2060 年碳中和的战略目标，我国正积极推进以生态保护为核心、绿色低碳为导向的可持续发展路径^{[1][2]}。就这样的背景下，汽车行业，以及锂电池快速检测行业成了能源转型上非常重要的一块。

“十四五”战略规划指出了方向，即燃油汽车逐步退市，因此新能源汽车有了大幅度增长^[3]。在政策导向的推动下，新能源汽车领域对锂电池的应用日益广泛，从而带动了其市场需求显著攀升。其中，锂电池的健康使用寿命一般是 5-10 年，当汽车正在使用的锂电池组的整体容量达不到初始使用时的容量 80%时，电池性能无法满足车辆运行需求时，将退役回收^[4]。据 2024 年 12 月 31 日最新统计数据显示，我国新能源汽车保有量已达 3140 万辆，其中纯电动汽车占比 70.34%（2209 万辆）。值得注意的是，2024 年新能源汽车新增注册量突破 1125 万辆，同比增幅达 51.49%，呈现出强劲增长态势。市场预测表明，至 2025 年，我国新能源汽车领域将产生约 78 万吨退役锂电池，并且更多的，在这之后锂电池退役量每年都会有超过百万量级^[5]。

与此同时，工业也在快速的发展，人类大量的使用化石能源，这些情况造就了能源短缺和环境遭到污染的问题^[6]。汽车的大规模普及，也是全球性现有的能源危机和温室效应加剧的重要诱因，综上事件和影响，愈使得新能源汽车凭借其绿色低碳的优势受到各国政府的大力支持和消费者的广泛青睐^[7]。各国纷纷出台补贴、免税等利好政策，推动新能源汽车技术不断进步，新能源汽车在性能和续航里程上逐渐缩小与传统燃油车的差距，配套产业也迅速发展^[8]，进一步提升了新能源汽车的市场竞争力，促进了其在全球范围内的快速普及。

然而，锂电池是新能源汽车里面的非常重要的动力源和关键部分，其使用年

限和性能对新能源汽车的市场竞争力有着重要影响^[9]。当前，新能源汽车仍面临着续航里程相对较短、充电设施不完善以及锂电池价格高昂且寿命衰减等问题，这些问题严重钳制了新能源汽车的进一步发展，也使得提升锂电池寿命、回收和检测技术的发展成为新能源汽车行业亟待解决的关键问题^[10]。

本研究聚焦于锂电池 SOH 的快速精准评估问题，创新性地将蜣螂优化算法 DBO 与 BP 神经网络相结合，构建了一种新型 SOH 预测模型，有效提升了评估精度。通过对锂电池的工作原理及基础性能进行系统性实验与分析^[11]，本文以锂电池的容量-电压数据为基础，对容量-电压曲线进行微分处理，提取容量增量曲线^[12]，并以其最大值作为关键特征变量，构建容量增量特征与锂电池健康状态之间的映射模型，进而可以准确的估算锂电池 SOH。

为了更好地提高方法的实用性和效率，本文主要对传统容量增量分析方法存在的数据获取时间太长的的问题，进行了创新性的改进，提出基于部分充电数据的特征提取策略。通过优化选择数据的范围，减少了对完整充放电数据的需要，从而缩短检测的时间，同时，确保了检测的精确性。本文的方法不仅是把容量增量和智能优化算法结合在一起，提高了锂电池 SOH 的估算精度还有鲁棒性^[13]，而且通过部分充电数据的特征提取策略，提高了检测的效率，为锂电池的 SOH 的预测和估算提供了一个比较可靠的技术支持。

1.1.2 研究意义

在新能源汽车产业高速发展的背景下，动力电池的性能稳定性已成为制约车辆安全性和运行效能的核心要素^[14]。如果能够对锂电池的健康状态进行准确快速的评估，不仅能更早发现电池的老化情况，从而给出及时维修或更换电池的科学依据，也可以大大提高电动汽车的安全性，避免因电池突然失灵导致的车辆故障，切实为驾乘人员的生命安全保驾护航^[15]。

从经济性角度分析，动力电池成本构成了纯电动汽车总成本的主要组成部分^[16]。科学评估电池 SOH 有助于建立系统化的电池管理机制。通过优化电池荷电状态（State of Charge, SOC）的精确控制^[17]，可有效避免电池过充过放现象，这不仅能够延长电池循环寿命，还可显著降低用户使用成本，提升车辆整体经济

效益。

退役电池的再次利用和资源回收同样需要依赖于对锂电池健康状态的准确快速的检测^[18]。新能源车退役后，它的动力电池一般情况下仍具备一定能量存储能力。精准高效的电池 SOH 评估技术为锂电池梯次利用提供重要技术支撑^[19]，有利其在低速电动载具、分布式储能系统及智能家居设备等场景的安全运行。该技术既可充分挖掘电池残余价值^[20]，又能缓解生态压力与资源浪费问题，通过构建“检测-应用-再生”全产业链闭环，实现环境效益与经济效益的协同提升。对于评估未达标的退役电池，采用梯度化再生利用工艺（拆解提纯、材料修复、定向冶金等），可减少 45% 以上的原生资源开采需求，高度契合循环经济发展理念^[21]。

在产业发展方面，其中锂电池 SOH 估算方法的研究与应用，是完善废旧锂电池利用技术体系、提升产业整体发展水平的重要驱动力。快速的电池 SOH 估算能够增强锂电池的再利用和资源节约，降低检测成本提高产品竞争力^{[22][23]}。此外，该技术还为新能源汽车产业链上下游企业，如电池检测设备制造商、电池回收企业、梯次利用产品开发商等，提供了新的发展机会，其还促进了产业的协同发展，助力构建出更加完整、成熟的产业链生态^[24]。

当前，锂电池 SOH 估算领域，尚未建立完善的强制检验检测规定，而锂电池性能对整车的动力、经济和安全性能有着直接影响^[25]。开展锂电池 SOH 估算研究，有助于建立科学的检测方法 with 评价指标，填补检测标准空白。

综上所述，锂电池 SOH 快速准确估算在新能源汽车安全与经济运行、退役电池合理利用、新能源汽车产业的发展，以及在社会可持续发展等方面均提供了不可替代的作用^[26]。深入研究锂电池健康状态检测技术，不仅能有效解决当前新能源汽车发展面临的诸多问题，推动产业朝着健康、稳定、可持续方向发展，助力我国“双碳”目标的实现，还能为全球能源转型与环境保护贡献力量^[27]，该研究在理论探索与工程实践领域均展现出显著的学术价值与应用潜力。

1.2 国内外研究现状

锂电池凭借其优异的高比能量特性、出色的循环稳定性以及极低的自放电性能，已成为新能源汽车、消费电子及大规模储能等领域的核心能源载体。然而，

在使用过程中，锂电池受到内部复杂的电化学反应和外部环境因素的影响，其性能有了逐渐衰退，锂电池 SOH 不断下降^[28]。准确快速的估算锂电池 SOH，对保障电池系统平稳运行，延长使用寿命，提高经济效益方面都至关重要^[29]。

1.2.1 国外研究现状

等效电路模型（ECM）：国外学者广泛利用 ECM 模拟锂电池的电气特性，通过电路元件（电阻、电容等）描述电池的动态行为^[30]。如 Ragone 等提出的二阶 RC 等效电路模型，这个模型能够很好地反映电池的极化效应。通过辨识建立的模型参数^[31]，如欧姆电阻、极化电阻和电容值的变化，可估算锂电池的 SOH。为提高模型精度，Verbruggen 等采用自适应算法在线调整模型参数，以适应不同工况下电池特性的变化。

电化学模型：以 Newman 等提出的多孔电极理论为基础的电化学模型，能深入描述电池内部的电化学反应过程，包括离子扩散、电荷转移等。该模型^[32]可精确预测电池的性能和 SOH，但计算复杂度高，需要大量的电池内部参数。为解决这一问题，Plett 等提出降阶的电化学模型，在保证一定精度的前提下，降低了计算成本，使其更适用于实际应用^[33]。

支持向量机（Support Vector Machine, SVM）在锂电池 SOH 的精确评估中展现了卓越的性能优势^[34]。德国学者 Schölkopf 等利用 SVM 对电池的充放电数据进行训练，建立电池 SOH 与特征参数之间的映射关系。通过优化计算的函数和参数，使得 SOH 预测的准确性得到了提高^[35]。为克服 SVM 在小样本数据下的局限性，美国学者 Cawley 等提出了多类 SVM 集成方法，有效提高了模型的泛化能力。

特斯拉（Tesla）研究团队创新性地应用长短期记忆神经网络（Long Short-Term Memory, LSTM）对电动汽车动力电池的历史运行数据进行深度挖掘^[36]，通过建立时间序列预测模型，实现了对电池 SOH 演化规律的精准把握。谷歌旗下的 DeepMind 公司将强化学习算法与神经网络相结合，实现了对电池 SOH 的动态预测，提高了预测的实时性和准确性。

内阻是反映电池健康状态的重要参数，国外研究人员通过交流阻抗谱（EIS）、

直流内阻（DCIR）等技术测量电池内阻^[37]。日本学者 Yoshino 等通过研究发现，电池内阻随 SOH 的降低而增大，且在不同温度和充放电倍率下，内阻与 SOH 之间存在一定的对应关系。为实现内阻的快速、准确测量^[38]，美国 A123 系统公司开发了一种基于高频脉冲电流注入的内阻测量方法，能够在短时间内获取电池的内阻信息。

在充放电过程中，电池的 SOH 也会伴随着温度而发生变化。如韩国三星公司的研究团队，他们布置多个温度传感器在电池的表面，以此监测电池不同部位的温度，并且利用热成像技术分析电池的热特性，据此判断锂电池的 SOH^[39]。其实验结果表明，电池的温度分布不均匀性随着 SOH 的降低而增大，通过分析温度分布特征可有效检测电池的健康状态。

1.2.2 国内研究现状

国内学者在传统等效电路模型基础上进行改进，以提高对锂电池 SOH 估算的准确性。清华大学的研究团队提出一种考虑电池老化过程中参数时变特性的改进等效电路模型，通过引入状态空间方程对模型参数进行在线估计，实现了对电池 SOH 的精确预测^[40]。上海交通大学的学者将模糊逻辑与等效电路模型相结合，根据电池的工作状态自适应调整模型参数，提高了模型在复杂工况下的适应性。

为综合利用不同模型的优势，国内学者提出多种混合模型。浙江大学的研究人员将电化学模型与等效电路模型相结合^[41]，建立了一种能够描述电池内部电化学反应过程和外部电气特性的混合模型。通过对混合模型的参数辨识和优化，实现了对电池 SOH 的高精度预测，同时降低了计算复杂度。

随着深度学习算法也在国内锂电池的 SOH 估算领域得到广泛应用。中国科学院的研究团队利用卷积神经网络（CNN）对电池的充放电曲线进行特征提取，结合全连接层建立 SOH 预测模型。实验表明，该团队的模型能够有效的提取出锂电池曲线中的存在的隐含特征，通过这些数据对 SOH 的估算精度明显优于传统的机器学习方法。复旦大学研究团队创新性地将生成对抗网络（Generative Adversarial Network, GAN）与长短期记忆神经网络（Long Short-Term Memory, LSTM）进行深度融合^[42]，构建了一种新型电池 SOH 预测框架。该模型通过引

入对抗性训练机制，显著提升了预测系统的泛化性能和评估精度。

国内学者则采用集成学习方法，想要以此来提高模型的稳定和可靠性^[43]。其中，哈尔滨工业大学的研究团队将多个不同类型的机器学习模型进行集成，其中有如 SVM、决策树、神经网络方法等，最终通过投票机制确定 SOH 的预测结果。实验结果表明，集成学习框架通过优化多模型协同机制，实现了预测性能的显著提升，能够提高 SOH 预测的准确性和鲁棒性。

除了上述方法应用较多外，国内学者亦是对超声波检测锂电池 SOH 的方法有着深入研究^[44]。其中重庆大学的研究团队通过向电池内部发射超声波，然后根据超声波在电池内部传播过程中的反射、折射和衰减的特性，获取电池内部的结构和材料的变化信息，根据这些信息估算锂电池的 SOH。实验表明，利用超声波检测法能够有效的检测出电池内部的电极腐蚀、电解液干涸等故障，为锂电池 SOH 估算提供了新的技术手段。

目前，光学技术检测锂电池 SOH 也是国内研究的一大热点^[45]。南开大学的研究团队通过开发一种基于光纤布拉格光栅（FBG）的传感器，实时监测电池在充放电过程中的应变变化，进而推断电池的 SOH。这种方法的优势在于灵敏度高、抗干扰能力强，为电池 SOH 的估算增添了新的思路。

1.3 本文研究内容

针对锂电池 SOH 检测问题，查阅了大量的国内外参考文献，梳理和分析了当前锂电池快速检测技术的研究现状，对其优缺点进行了借鉴和改善，并进行了锂电池的基础实验研究，提出了基于部分充电数据的容量增量法与 DBO-BP 算法相结合的新方法，并通过公开数据集进行验证。本文的具体内容如下：

第 1 章阐述了锂电池 SOH 评估的研究背景与学术价值，系统梳理了国内外 SOH 估算技术的研究进展，同时明确了本研究的核心目标与技术路线。

第 2 章重点解析了锂离子电池的结构特征与工作机制，深入探讨了其内部电化学反应动力学过程，并详细分析了导致电池性能衰减的关键影响因素。然后，分析了现有的 SOH 估算方法的原理和局限性，为后续的研究奠定理论基础和方向。

第 3 章进行了一系列实验，针对锂电池的基本性能研究，包括不同倍率的充

放电容量特性实验、HPPC 实验，实验后对获取的实验数据进行分析。进而，明确锂电池充电过程中，充电中期的数据更有益于锂电池 SOH 的准确评估，HPPC 方法太过缓慢不利于锂电池 SOH 的快速检测。

第 4 章详细阐述了融合容量增量法与 DBO-BP 算法结合的检测方法，利用公开数据集进行实验，得到经 DBO 优化的 BP 神经网络建立的模型对估算 SOH 的精度有明显提升的结论。

第 5 章通过分析容量增量曲线和时间的关系，发现部分区间数据对预测至关重要，结果表明基于部分充电数据的方法，不仅减少了数据需求，提升了 SOH 估算的速度，此外估算精度也得到提高。

第 6 章总结了本研究在理论方法与技术创新方面的主要贡献，提出了未来在实验数据及工程应用方向的深入研究建议。

第2章 锂电池工作原理及 SOH 估算方法

锂电池作为现代社会广泛应用的化学电源,其性能和特性对于众多领域的发展至关重要,其 SOH 估算也是重中之重。从微型消费电子产品到大规模电动交通工具,锂电池技术已深度渗透现代生活的各个领域。深入理解其电化学工作机制与性能衰减机理,将为电池 SOH 的精确评估提供重要的理论支撑和实践指导。本章主要描述锂电池的基本构造和工作原理,并对锂电池的老化机理和锂电池 SOH 的估算方法进行简单概述。

2.1 锂电池基本构造与工作原理

锂电池的基本结构包含正极、负极、电解质和隔膜四个核心组件^[46]。

正极材料提供锂离子电池内部化学反应的所有活性锂离子,为了提高电池容量,正极材料必须能够结合大量锂。此外,正极材料必须可逆地交换该锂而几乎没有结构变化以允许长循环寿命、高库仑效率,并且不溶于电解质,由廉价试剂以低成本合成制备,具有高锂离子扩散性和良好的电子传导性以确保高能量效率^[47]。目前主流的正极材料体系包括层状氧化物(如锂钴氧化物、锂镍氧化物)、尖晶石结构(如锂锰氧化物)以及橄榄石结构(如磷酸铁锂)等。

负极材料通常使用锂化石墨,其在铜集流体上具有层状结构^[48],一般为 Li_xC_6 、 TiS_2 和 V_2O_5 等。通常将 LiPF_6 和 LiClO_4 等锂盐可溶的有机溶剂作为电解液。而隔膜用来防止正负极接触,避免电池内短路。通常应用聚合物材料来制成隔膜,使得其具有较好的导电性和化学稳定性,能够经受电解液的腐蚀和高温高压的恶劣环境^[49]。此外,隔膜还能起到限制离子扩散和调控电池内部电荷传输的作用,影响电池的性能表现。

锂电池的工作原理,基于锂离子在正负极材料间的可逆嵌入/脱嵌反应^[50]:充电过程中,锂离子从正极材料晶格中脱出,经电解质迁移并嵌入负极材料,同时电子通过外电路转移;放电时则发生相反的离子迁移过程,从而实现化学能与电能的高效转换。

以磷酸铁锂电池(Lithium Iron Phosphate, LFP)为例^[51],在充电过程中, Li^+ 在

阴极处从 LiFePO_4 逸出，在电动势的影响下， Li^+ 通过电解质最终嵌入到石墨的碳夹层之中。当到放电过程， Li^+ 又在电动势的影响下，通过与前文相反的过程，从阳极的碳夹层之中，逸出嵌入到阴极 LiFePO_4 中。该过程可使用化学反应方程式表达，以及锂电池在这个过程的内部变化示意如图 2-1。

充电方程：



放电方程：




图 2-1 锂电池充放电过程示意图

2.2 锂电池老化机理

在锂电池的循环使用过程中，持续的充放电操作驱动着电极材料内部发生可逆的电化学反应^[52]，这些反应会使锂离子电池内部材料的结构和性能发生变化，其性能衰减主要表现为容量衰减（Capacity Fade）和功率衰减（Power Fade）。这种衰减主要源于两方面的老化机制：循环老化（Cyclic Aging）和日历老化（Calendar Aging）。循环老化与充放电次数直接相关，而日历老化则与时间相关，即使在静置状态下也会发生^[53]。国际能源署（IEA）有统计数据表明，动力电池在使用过程中，经历 800 次深度循环后，其平均容量将衰减 20%，此外放到

高温（45℃）环境储存 12 个月，其容量损失也可达到 15%。下文将系统探讨影响锂电池性能衰减的关键因素及其作用机制。

2.2.1 正负极材料老化

电化学循环引发的锂离子持续嵌入/脱出行为，促使电极晶格有周期性的体积应变^[54]。这种机械形变的累积效应，将会引发材料内部的应力集中现象，具体表现为晶界开裂、颗粒破碎以及导电网络断裂等多尺度结构损伤。循环过程中，过渡的金属元素溶出及表面的重构反应，会显著的削弱电极材料的电荷传递能力。

2.2.2 固态电解质膜老化

固态电解质的界面层的动态变化呈现出复杂的特征：一方面，有机/无机成分的梯度分布会随循环次数增加发生显著改变；另一方面，电极的体积波动产生的应力可能会破坏膜层的结构完整性^[55]。这种变化将导致锂离子扩散势垒升高，并会加剧活性物质的不可逆消耗。

2.2.3 电解液老化

在长期的使用过程中，电解液面临着诸多挑战^[56]：（1）锂盐组分的热力学不稳定性引发水解副反应；（2）高电位工况下溶剂分子的电化学氧化分解；（3）过渡的金属离子引发的催化降解链式反应。这些因素不仅会降低电解质本身的导电性，更会生成腐蚀性物质加速腐蚀过程，影响锂电池的 SOH。

2.2.4 电极/电解质界面老化

电极/电解质界面的电化学稳定性直接影响锂离子传输动力学特性^[57]。主要影响因素包括：电解质分解导致的固液界面阻抗增加；电极材料的膨胀引起的界面接触失效；以及电化学极化引起的空间电荷层重构。这些耦合效应最终导致锂电池性能降低。

2.2.5 其它因素

锂电池的自放电现象主要源于电极与电解质之间的自发氧化还原反应,这种非工作状态下的容量损失会显著影响电池的存储性能。此外,工作温度是影响电池老化速率的关键因素,高温环境会加速电极材料的结构衰退和电解质的热分解。其他环境因素如湿度、光照强度和机械振动等也会对电池性能产生不同程度的影响^[58]。

2.3 锂电池 SOH 的估算方法

2.3.1 基于物理特性的估算方法

SOH 是反映电池在长时间循环使用中受温度、充放电电流大小等影响而逐渐老化的主要参数^[59]。准确的 SOH 估算直接影响锂电池性能的发挥,为了确定 SOH,我们通常会比较电池的当前满电状态下的能量与新电池在满电状态下的能量,并计算它们之间的比值。

$$SOH = \frac{Q_i}{Q_0} * 100\% \quad (2-3)$$

式中: Q_i 为老化后的电池的实际容量; Q_0 为电池出厂标定的额定容量。

如图 2-2 为磷酸铁锂电池,在充放电(恒流、恒压充电和恒流放电)过程中,其电流与电压的变化示意图。



图 2-2 磷酸铁锂电池充放电过程的电流电压变化图

容量测量法，是经典的一种测试方法，其直接测量电池的最大可用容量，通过衰减程度来评估 SOH^[60]。该方法需对电池进行完整的充放电循环（通常耗时 4–8 小时），且在恒流放电阶段记录截止电压对应的容量值。尽管该方法精度高（误差<2%），但因耗时太久，无法用于锂电池 SOH 的快速检测。

$$Q = \int_{t_0}^t I(\tau) d\tau \quad (2-4)$$

电池内阻（包括欧姆阻抗、电荷转移阻抗等）与 SOH 呈非线性负相关。直流内阻法通过阶跃电流响应计算内阻，而交流阻抗谱（EIS）则在 0.1 – 10 kHz 频率范围内测量复数阻抗^[61]。研究表明，锂离子电池欧姆阻抗每增加 15%，容量衰减约 8%。例如，A123 LFP 电池在循环 500 次后，电荷转移阻抗从 12 mΩ 升至 28 mΩ，对应 SOH 下降至 78%。然而，内阻易受温度波动影响（温度每升高 10° C，阻抗降低约 5 – 8%）。

2.3.2 基于物理模型的估算方法

电化学机理模型，基于多孔电极理论（P2D 模型）和能斯特方程，可量化 SEI 膜增厚、活性锂损失等老化机制^[62]。例如，通过耦合负极 SEI 生长动力学方程，模拟表明 SEI 膜厚度每增加 1 μm，电池容量衰减 3.2%。该模型需精确输入电极孔隙率、扩散系数等参数（误差敏感度达±5%），且计算复杂度高（单次仿真耗时>10 分钟），实际应用仍有不小阻拦。

等效电路模型（ECM），以 Rint 模型为例：




图 2- 3 Rint 模型

其表达式为：

$$V_{terminal} = V_{OCV} - I \cdot R_0 - V_{pol} \quad (2-5)$$

其中， R_0 为欧姆内阻， V_{pol} 为极化电压。当将递推最小二乘法（RLS）应用

在线辨识参数时，建立的模型对 0.5C 以上倍率的 SOH 估算误差达到 $\pm 4\%$ ^[63]。Thevenin 模型在 25°C 下对 NMC 电池的 SOH 估算均方根误差(RMSE)为 2.3%，但在低温（-10°C）下误差增至 5.8%。

2.3.3 基于算法分析数据的估算方法

传统的机器学习算法^[64]，该方法从充放电的曲线中提取健康因子（Health Indicators, HIs），包括恒流的充电时间、电压的平台斜率等。例如，支持向量回归（SVR）利用 NASA 数据集中的充电电压拐点特征，SOH 估算 RMSE 为 2.1%，但需人工筛选特征（耗时>30 分钟/周期）。随机森林（RF）通过集成学习降低噪声干扰，在 100 次循环数据训练后，对 LFP 电池的预测误差<3%。

BP 神经网络，其构建了多层的前馈结构（输入层、隐含层、输出层），用来实现锂电池 SOH 的非线性映射。其输入特征通常选取与 SOH 强相关的健康因子（HI），如充放电过程中的电压平台斜率、恒流充电时间、容量衰减率及等压降放电时间^[65]。以 NASA 数据集为例，输入层接收标准化后的电池输出电压（3.6 - 4.2V）、输出电流（0.5 - 2C 倍率）、容量（标称值 80 - 100%）等时序数据，隐含层通过 Sigmoid 激活函数提取老化特征，输出层则生成 SOH 百分比预测值。训练过程中采用反向传播算法调整权重矩阵，结合遗传算法（GA）优化初始权重分布，然后输出模型进行估算 SOH，但电压拐点区域误差会高至 8%。




图 2-4 BP 神经网络示意图

2.4 现有研究的局限性

表 2- 1 SOH 检测方法对比

方法	优点	缺点	本方法改进
放电实验法	精度高	耗时>4h，损伤电池	数据量减少 83%
阻抗分析法	机理明确	设备昂贵(>\$50k)	无需专用设备
容量增量法	实时性好	依赖完整充电周期	部分数据(30min)即可
传统 BP 神经网络	非线性建模能力强	易陷局部最优	DBO 优化提升 35%收敛速度

尽管国内外学者在锂电池 SOH 评估领域已取得显著研究成果，然而现有估算方法在准确性、实时性和适用性等方面仍存在亟待解决的技术瓶颈。一方面，各类模型和算法存在局限性。如传统方法需采集 4-8 小时完整充放电数据（如 HPPC 实验耗时 ≥ 10 小时），而实际运维场景要求 30 分钟内完成诊断；等效电路模型在表征锂电池内部复杂的电动力学过程方面存在明显局限性；电化学模型虽理论精确，但计算成本高，对电池内部参数依赖大，实际应用受限；机器学习算法依赖大量高质量数据，数据不足或质量不高时，预测精度和泛化能力下降，且模型可解释性差，难以直观理解其预测依据。另一方面，SOH 检测技术的通用性和适应性有待提高。不同类型、不同应用场景的锂电池特性差异大，现有的检测方法难以在各种条件下都保持高精度和可靠性。同时，多种检测技术融合的系统性研究还不够深入，尚未形成全面、高效、可靠的综合检测体系，难以满足实际应用中锂电池 SOH 快速、准确检测的需求。总结：现有研究要求大量高质量充放电及其他数据，在精度和检测速度上不能兼顾。

本文基于部分充电数据，减少对充放电数据的需求，使用融合容量增量方法与算法结合的快速检测方法，在提高检测精度的同时，实现快速检测。

2.5 本章小结

锂离子电池通过正负极锂离子可逆脱嵌实现能量存储,其性能受正极材料结构稳定性及隔膜离子调控能力制约,典型磷酸铁锂体系放电中期呈现平稳电压平台,末期极化效应显著。电池老化由循环/日历老化耦合驱动,涉及电极机械疲劳、SEI膜增厚及电解液降解等多机制。SOH估算方法中,容量法(误差 $<2\%$)和阻抗谱分析精度高但快速性受限;等效电路模型通过动态参数辨识实现误差 $\pm 4\%$,但是计算精度要求高、获取数据也需要较多时间;而数据驱动方法依托电压平台斜率等特征实现 3% 级误差快速预测,需解决收集大量数据的问题。三类方法在检测精度与速度层面各有优缺点,本文研究目标是在保证检测精度的基础上提升检测速度。

第3章 锂电池基本性能实验

3.1 实验背景

在锂电池健康状态评估研究前，熟悉该类型电池的化学特性与工作原理是首要工作。基于此，通过实验手段全面分析锂电池的容量、内阻变化规律，对于构建准确的 SOH 估算模型具有重要的理论价值与实践指导意义^[66]。

锂电池容量特性的研究，是洞悉其储能能力、了解锂电池基本性能的关键所在。通过剖析电池充放电过程中电压与容量的关联，我们能够揭示放电阶段不同时期的电压变化规律；探究不同充放电倍率对电池放电容量的影响，可为合理使用电池、精准估算锂电池健康状态提供依据^[67]。掌握这些因素，有助于我们更透彻地了解锂电池基本性能，进而更高效、准确地评估电池健康状态。

对锂电池等效模型的研究，即开展 HPPC 实验，是认识电池内部特性与动态行为的重要方法。等效模型以数学和物理方法描述电池电学特性，为深入理解电池性能、估算健康状态筑牢理论根基^[68]。HPPC 实验则能深入探究电池在不同核电荷状态下的动态响应，获取电池内阻、极化等关键参数，为估算电池健康状态提供重要参考。

综上所述，本章节将围绕锂电池的基本性能展开研究。首先阐述研究锂电池基本性能的重要性，随后介绍实验平台，深入研究不同充放电速率对放出容量的影响，再开展 HPPC 实验。本章节的研究将基于磷酸铁锂电池展开，旨在通过一系列实验和分析，揭示锂电池的基本性能，为认识锂电池和后续实验检测、改进锂电池健康状态检测方法提供可靠的理论依据和实践指导。

3.2 实验平台搭建

3.2.1 实验电池

本实验选用国产超越科技公司提供的磷酸铁锂（ LiFePO_4 ）软包电池作为测试对象，其标称电压为 3.2V，标称容量 20Ah。该电池体系具有以下优势：其一， LiFePO_4 材料具有优异的热稳定性和化学惰性，显著降低了热失控风险；其二，

表现出卓越的循环性能，可支持数千次充放电循环，有效降低了全生命周期使用成本。同时，电池能量密度合理，兼顾电量存储与性能。软包设计还让电池形状可灵活定制，能更好适配不同设备的安装空间。电池参数如表 3-1：

表 3-1 20Ah 电池数据相关信息

参数	规格
额定容量	20Ah
材料	LiFePO4
1C 充电电流	20A
恒压充电截止电流	1A
放电截止电压	2.5V
充电截止电压	3.6V

新电池实验前，需要进行激活：首先以 0.5C 恒流放电至截止电压 2.5V，静置 10 分钟；随后采用 0.5C 恒流充电至上限电压 3.6V，切换为恒压模式，当充电电流降至 0.05C 时终止，静置 30 分钟；最后重复上述充放电循环三次以完成电池激活。

充电倍率 C 是表征电池充放电性能的重要指标，其数学表达式为充放电电流（A）与电池标称容量（Ah）的比值^[69]。具体而言，该参数反映了在特定时间范围内完成电池完全充电所需的电流强度。以标称容量为 20Ah 的电池为例：当充电倍率为 1C 时，对应充电电流为 20A，即电池可在 1 小时内完成充电；若充电倍率降至 0.5C，则充电电流相应减小至 10A，此时完成充电所需时间延长至 2 小时。



图 3-1 实验用的 20Ah 电池

3.2.2 高精度可编程充放电设备

本实验采用 CTE-4008 D-5V30A 型电池检测系统（深圳市新威尔电子有限公司），其技术规格包括 5V 电压量程和 30A 电流量程，支持 8 通道同时进行数据的采集，在电压和电流的测量精度上都能达到 0.05%FS。该系统配备的控制软件界面友好，功能全面，能够设计基础充放电测试和复杂老化循环实验，实时监控多通道电池状态，并独立识别各通道异常^[70]。

在数据管理方面，系统具备完善的采集与保护机制：实验过程中实时采集并存储各通道的充放电数据，为后续分析提供可靠的数据支撑。系统采用非易失性存储技术，确保在发生系统故障、意外断电或通信中断等异常情况时，实验数据的完整性和连续性得以保障，实现系统恢复后的无缝数据对接。



图 3-2 新威充放电设备及上位机软件

表 3-2 新威充放电测试仪的主要技术参数

参数	参数详情
设备物料编码	CTE-4008 D-5V30A
输入电源	AC 220V ±10% / 50Hz
分辨率	AD: 16bit; DA: 16bit
电压精度	± 0.05% of FS
电流精度	± 0.05% of FS
数据记录	最小时间间隔：100ms（记录频率 10Hz） 最低电压间隔：10mV
最小脉冲宽度	500ms

续表 3-2 新威充放电测试仪的主要技术参数

参数	参数详情
上位机通讯方式	基于 TCP/IP 协议
服务器操作系统	Windows 7、Windows10
整机通道数	8

表 3-3 上位机配置

参数	参数详情
处理器	I5-3337U
RAM	4.00GB
系统版本	Windows 10 专业版
系统类型	64 位操作系统

3.2.3 实验条件

实验过程中,我们针对关键变量进行了严格管控。鉴于实验室恒温条件有限,通过空调系统将室温稳定在 25℃左右,最大限度降低温度波动对锂电池性能的干扰。在通风条件方面,受实验室空间限制,我们选择将实验区域靠近窗户,并保持长期开启状态,利用自然通风降低有害气体积聚,确保实验人员安全^[71]。为减少电磁干扰对实验数据的影响,所有检测设备均集中安置于实验室角落,远离配电箱等可能产生电磁干扰的设施,从而保证实验数据的可靠性。实验采用离线检测模式,充放电过程通过高精度程控设备(CTE-4008 D-5V30A)完成,数据采集间隔设置为 10 秒,全程脱离车载 BMS 系统运行,符合 GB/T 31486-2015 规定的离线检测规范。

3.2.4 实验评价指标

为定量验证不同方法计算的误差,采用多种评价指标对计算结果进行分析对比,误差数值越小、R²的数值在 0-1 的区间内越接近 1 估计结果越准确。

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

(3- 1)

$$MAE = \frac{1}{n} \sum_{i=1}^{\infty} |Y_i - y_i| \quad (3-2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{\infty} (Y_i - y_i)^2} \quad (3-3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3-4)$$

式中： Y_i 是第 t 个样本的实际值； y_i 是第 t 个样本的预测值； n 是样本个数。

3.3 不同放电倍率下的锂电池放电容量实验

3.3.1 实验步骤

本实验按照以下步骤开展：首先，采用 0.5C 的恒流对电池放电，直至电压达到截止电压 2.5V 时终止；随后，以 0.5C 的恒流对电池充电至 3.6V，静置 5 分钟，然后切换到恒压充电的模式，恒压充电直至电流数值大小降至 0.05C，即完成充电过程；放电阶段，分别选取 0.1C、0.25C、0.5C、0.75C、1C 和 1.5C 六个不同倍率的恒流放电电流大小，至电池电压降低至截止电压 2.5V 时停止放电，完成整个实验的操作流程如图 3-3。通过这一实验流程，可以全面的评估电池在不同放电倍率下的性能表现。




图 3-3 不同放电倍率的实验流程图

3.3.2 实验结果

该实验，充电速率均为 0.5C（10A），除放电速率不同外，其余条件保持一致，实验环境空调室内 25℃。实验过程中，没有外部因素干扰、中断实验。实验过程一致，按“实验步骤”进行。

数据汇总如下表：

表 3-4 放电数据汇总

放电倍率	实验耗时	恒流充入容量/Ah	恒压充入容量/Ah	恒流放出容量/Ah
1.5C	3h17min	19.9571	0.6020	19.9026
1C	3h31min	19.8913	0.4949	19.9011
0.75C	3h50min	19.8350	0.5022	19.9802
0.5C	4h30min	20.0882	0.4250	20.1322
0.25C	6h37min	20.0193	0.5595	20.4194
0.1C	12h48min	20.0406	0.5337	20.5137

从数据中可看出：同样是进行的 0.5C 恒流充电，但是不同放电倍率对应的恒流充电阶段充入电池的容量不同。原因分析：在 1.5C、1C、0.75C 实验之前，刚做过高倍率的放电实验，高倍率放出容量较少，导致接下来的所需充入容量也较少。

绘制时间-电压曲线如下：




图 3-4 不同放电倍率下电压随时间变化曲线

曲线从左到右，依次从 1.5C 倍率到 0.1C 放电倍率。

图示分析表明：曲线记录了电池不同放电倍率的放电特性。初始阶段，所有放电曲线的电压均为 3.41V，表明多次充放电过程中的充电参数得到有效控制，确保 6 组不同倍率放电实验前的初始条件一致。

从图示曲线可以看出，锂电池的不同放电倍率与端电压呈现显著相关：放电倍率越高，其对应的端电压下降速率就越快。这一现象源于高倍率放电时电流增大，导致电池内部化学反应速率加快，内阻显著增加，从而引起电压快速下降。

绘制电压-容量曲线如下：




图 3-5 不同放电倍率下的电压-放出容量曲线

曲线从上到下，依次从 0.1C 倍率到 1.5C 放电倍率。

电池的放电倍率显著影响着其性能。高倍率放电时，电池内阻迅速增加，极化效应加剧，致使电池内部电化学反应无法匹配放电速度，端电压快速下降，最终放出容量减少。与之相反，低倍率放电时，电池能维持长时间的稳定电动势，内阻变化平缓，电化学反应可较好地满足放电需求，电压下降较慢，从而释放出更多容量。随着放电倍率的增加，电池内阻不断增大，端电压下降愈发明显，高倍率放电时内阻增加更为突出，所以电压下降速度更快。

放电中期，电池端电压变化较为平缓的下降。此时，电池内部化学反应速度与电子移动速度基本平衡，极化导致的电压变化也趋于稳定。该阶段电压缓慢下降主要和电池电动势、欧姆内阻相关。电动势与电解液浓度有关，欧姆内阻随放电逐渐增大，但二者变化都较为平缓，所以电压呈缓慢下降趋势。这一阶段的电压特性，对评估电池性能意义重大。

放电后期，锂电池的电压则迅速下降，且放电倍率越大时其下降趋势就越快。高倍率放电时对应的锂电池极化效应更明显，原因在于电流密度增加致使电极表面反应产物积累、电化学反应存在动力学限制、内部电阻增大、电解液离子迁移速度不足，以及电池材料疲劳和电解质分解。这些因素共同作用，加剧了极化效应，进而加速电池电压下降，减少电池容量。

低倍率放电时，由于内阻效应、极化效应、热效应较小，电化学反应更充分，电池能够提供更多的可用电量。由此可见，电池的放电倍率与锂电池实际放电容量显著相关：在低倍率放电时，电池释放的电量更多。这也是为什么在许多应用中，电池厂商会建议使用较低的放电倍率以获得最佳的容量和寿命。

3.4 不同充电倍率下的锂电池放电容量实验

3.4.1 实验步骤

本实验按照标准化流程，包括预处理、充电和放电三个阶段。首先，以 0.5C 恒流放电至截止电压 2.5V，确保所有测试样本处于相同初始状态。随后，分别采用 0.1C 至 1.5C 的阶梯式充电倍率（0.1C、0.25C、0.5C、0.75C、1C、1.5C）进行恒流充电，当电池电压达到上限电压 3.6V 时终止充电。最后，再次以 0.5C

恒流放电至 2.5V，完成完整的充放电循环。实验开始前，对测试设备及电池样品进行全面的功能检测与校准。实验过程中，通过新威 CTE-4008 D-5V30A 系统，每 10 秒记录一次电池电压、电流及放电时间等关键数据。通过这一实验，能够全面评估电池在不同充电倍率下的性能表现，整个实验流程如图 3- 6。




图 3- 6 不同充电倍率的实验流程图

3.4.2 实验结果

该系列实验，放电速率均为 0.5C（10A），除充电速率不同外，其余条件保持一致，实验环境空调室内 25℃。实验过程中，没有外部因素干扰、中断实验。实验过程一致，按“实验步骤”进行。

数据汇总如下表：

表 3-5 充放电数据汇总

充电倍率	实验耗时	恒流充入容量/Ah	恒压充入容量/Ah	恒流放出容量/Ah
1.5C	2h48min	19.1569	-	18.9325
1C	3h09min	19.3816	-	19.166
0.75C	3h31min	19.6339	-	19.3749
0.5C	4h12min	19.8426	-	19.573

续表 3-5 充放电数据汇总

充电倍率	实验耗时	恒流充入容量/Ah	恒压充入容量/Ah	恒流放出容量/Ah
0.25C	7h18min	20.1721	-	19.8117
0.1C	12h31min	20.4838	-	20.043
1C	3h35min	19.512	1.007	20.1811
0.5C	4h28min	20.0587	0.5527	20.1803

从数据中可看出：同样的 0.5C 恒流放电的条件，不同倍率时的恒流充电阶段，充入容量不同。原因分析：在 1.5C、1C、0.75C 实验之前，刚做过高倍率的放电实验，高倍率放出容量较少，导致接下来的所需充入容量也较少。

在高倍率充放电时，电池内部由于极化效应和内阻变化，影响了电池的充放容量。当充电阶段只有恒流充电时，电池的充入容量和放出容量能够有很好的映射；当充电阶段分为恒流充电阶段加上恒压充电阶段时，电池最终放出的电量基本一致。

绘制时间-电压曲线如下：




图 3-7 不同充电倍率下电压随时间变化曲线

曲线从左到右，依次从 1.5C 倍率到 0.1C 充电倍率。

图示分析表明，曲线记录了在电池恒流充电阶段的电压变化。初始阶段，所有充电曲线的电压均为 2.65V，表明多次充放电实验中的充电参数得到有效控制，确保 6 组不同充电倍率实验的初始条件一致。

从曲线的趋势看出，锂电池的充电倍率与端电压呈现显著相关：充电的倍率越高时，端电压的上升越快。这一现象源于高倍率充电时电流增大，导致电池内

部化学反应速率加快，内阻显著增加，从而引起电压快速上升。

绘制电压-容量曲线如下：




图 3-8 不同充电倍率的电压-充入容量曲线

曲线从上到下，依次从 1.5C 倍率到 0.1C 放电倍率。

随着锂电池的充电倍率越高，锂电池最终充入的容量就越少，随之锂电池放出的容量也减少。

高倍率充电初期，因充电电流较大，电池内部电动势迅速被提高，端电压通常会快速上升。

充电中期，电池端电压呈现平缓上升趋势，表明此时电池内部化学反应速率与电子迁移速率达到动态平衡，极化效应趋于稳定。这一阶段电压缓慢上升主要和电池电动势、欧姆内阻相关。电动势与电解液浓度有关，欧姆内阻随充电逐渐增大，但二者变化都较为平缓，所以电压呈缓慢上升趋势。该阶段的电压特性对评估电池性能意义重大。

充电后期，电压呈现快速上升趋势，且倍率越高上升速率越快，高倍率充电时极化效应更明显，这是由于电流密度增加致使电极表面反应产物积累、电化学反应存在动力学限制、内部电阻增大、电解液离子迁移速度不足，以及电池材料疲劳和电解质分解。这些因素共同作用，加剧了极化效应，进而加速电池电压上升，减少充入容量。

低倍率充电时，由于内阻效应、极化效应、热效应较小，电化学反应更充分，电池能够提供更多的可用电量。实验数据分析表明，充电倍率与电池实际充入容量呈显著负相关关系：在较低充电倍率（0.1C-0.5C）条件下，锂电池表现出更

高的可充电容量。

3.5 HPPC 实验

电池极化特性是电池研究和应用的关键。放电时，电化学反应速度跟不上电流需求，致使电池内阻增加、电压下降，这就是极化效应。高倍率放电时，电流密度增大，极化效应更明显，主要源于电极表面产物积累、反应动力学限制等因素。极化效应表现为高倍率充放电时，电池端电压快速变化、冲入/放出容量减少；低倍率时则变化平缓。

为深入探究电池在不同工况下的极化特性，并且获取更优锂电池模型，接下来将开展 HPPC（Hybrid Pulse Power Characterization）实验。该实验通过特定脉冲充放电模拟实际工况，解析极化特性，构建高精度锂电池模型。

3.5.1 实验步骤

参照《Freedom CAR 电池测试手册》设计 HPPC 的实验流程。首先，对电池进行 1C 的恒流恒压充电，充至电压达到截止电压 3.6V，停止后搁置 1 小时；然后进行 10s 的 1C 脉冲放电，静置 40s；接着进行 10s 的 0.75C 脉冲充电，再静置 5 分钟；然后再以 1C 的恒流放出电池 10% SOC 的电量，静置 1 个小时。重复执行脉冲放电、充电、静置及恒流放电的循环过程，直至电池的 SOC 降至 10% 以下。随后，以 1C 的放电倍率放电直至达到终止电压，从而完成 HPPC 测试。根据 HPPC 测试所获得的数据，运用以下公式来计算锂电池的核心性能指标：

$$R_0 = \frac{|\Delta U_{AB}| + |\Delta U_{CD}|}{2I} \quad (3-5)$$

$$\tau = -\frac{t_E - t_D}{\ln\left(\frac{U_A - U_E}{U_A - U_D}\right)} = R_1 C_1 \quad (3-6)$$

$$R_1 = \frac{U_B - U_C}{I \left(1 - e^{-\frac{t_C - t_B}{\tau}}\right)} \quad (3-7)$$

如图 3-9 为 HPPC 实验流程图：




图 3-9 HPPC 实验流程图

锂电池的一阶 RC 模型和 HPPC 实验的数据采集点如下：




图 3-10 一阶 RC 模型和理论脉冲测试过程

R_0 : 欧姆内阻, R_1 : 极化内阻, C_1 : 极化电容。

3.5.2 实验结果

下图为实际实验获取的电压变化图，可以看到其与原理图基本吻合。




图 3-11 实验得到的 HPPC 脉冲实验电压变化图

表中测试结果为脉冲电流 20A，脉冲时间 10s，DE 阶段 60s，测得的数据。

表 3-6 HPPC 实验数据

SOC	A 电压/V	B 电压/V	C 电压/V	D 电压/V	E 电压/V	R_0/Ω	R_1/Ω	C_1/F
1	3.3900	3.3338	3.2396	3.2929	3.3270	0.0027	0.0677	2048.4087
0.9	3.3270	3.2730	3.2256	3.2783	3.3195	0.0027	0.0088	3624.9647
0.8	3.3254	3.2720	3.2203	3.2732	3.3178	0.0027	0.0094	3308.7669
0.7	3.3231	3.2685	3.2136	3.2667	3.3140	0.0027	0.0105	3141.2987
0.6	3.2971	3.2430	3.1890	3.2420	3.2884	0.0027	0.0102	3188.1943
0.5	3.2954	3.2413	3.1754	3.2291	3.2772	0.0027	0.0170	2730.2189
0.4	3.2799	3.2222	3.1597	3.2172	3.2708	0.0029	0.0114	2730.2189
0.3	3.2800	3.2245	3.1537	3.2098	3.2688	0.0028	0.0134	2433.6728
0.2	3.2575	3.2015	3.1197	3.1755	3.2408	0.0028	0.0176	2147.6196
0.1	3.2088	3.1442	3.0328	3.0978	3.1882	0.0032	0.0228	1565.3631

将 A 点测得的电压值作为开路电压（Open circuit voltage，OCV）的参考值，下图呈现了通过计算得出的锂电池参数（ R_0 、 R_1 、 C_1 、OCV）与电池 SOC 之间的拟合关系曲线。从图中可以观察到，各参数与 SOC 之间存在一定的关联性，但其变化规律无法通过简单的一次或二次曲线进行准确描述。




图 3-12 电池模型的参数与电池 SOC 拟合示例

多元线性拟合方程: $SOC = -2.288048 + 315.018483 \cdot R_0 + 17.803033 \cdot R_1 + 0.000603 \cdot C_1$

多元线性拟合均方误差: $1.990159e-03$, $R^2 = 0.975877$

多元非线性拟合方程: $SOC = 4575.417297 - 3216398.429370 \cdot R_0 + 50128.105553 \cdot R_1 - 0.192471 \cdot C_1 + 586018398.593736 \cdot R_0^2 + 668.356371 \cdot R_1^2 + 0.000014 \cdot C_1^2 - 18031265.528938 \cdot R_0 \cdot R_1 + 38.329392 \cdot R_0 \cdot C_1 - 0.994935 \cdot R_1 \cdot C_1$

多元非线性拟合均方误差: $5.755304e-25$, $R^2 = 1.000000$

基于实验数据与相关分析,成功构建了电池在不同 SOC 状态下的等效电路模型参数。通过拟合方程及结果分析发现,电池的欧姆内阻、极化内阻以及极化电容均与 SOC 呈现很强的相关性。但是实验耗时太久。

3.6 本章小结

本章节聚焦锂电池基本性能展开研究,通过本章节实验和结果分析,更加了解锂电池的基本性能,便于开展后续实验。实验内容包括不同倍率充放电实验与 HPPC 实验,具体如下:

1、实验背景:锂电池广泛应用在诸多领域。研究锂电池容量特性、等效模

型以及开展 HPPC 实验，有助于深入了解电池性能，精准估算其健康状态。

2、实验平台搭建：选用超越科技生产的磷酸铁锂软包电池，阐述其优势与参数，并介绍新电池激活方式及充电倍率含义。采用新威尔电子的电池检测设备，说明设备参数、配套软件功能和上位机电脑规格。同时，说明了实验环境条件的控制方式，以减少温度、通风和电磁干扰等因素对实验的影响。

3、不同倍率充放电实验：在不同放电倍率实验中，发现低倍率放电时电池容量更多，高倍率放电则端电压下降快、容量少。在不同充电倍率实验里，低倍率充电充入容量多，高倍率充电时端电压上升快、充入和放出容量少。通过实验，明确了不同充放电倍率下容量不同的原因，以及相关数据特征和处理方式对映射电池容量关系的作用，还阐述了电池极化特性；另外，不同的充放电倍率的实验下，充放电初期、后期的电压变化大，不适于估算锂电池的 SOH，应着重利用到锂电池充电中期的数据。

4、HPPC 实验：通过实验获取了不同 SOC 状态下电池等效电路模型的参数，分析结果表明，电池的 SOC 与欧姆内阻、极化内阻及极化电容之间存在显著的相关性。其中，多元非线性拟合可精确预测 SOC，为电池的健康状态检测提供关键参考依据。该实验可以看出 HPPC 获取到的数据更能反映锂电池的变化及内部特征，较适用于锂电池 SOH 的准确估算，但是该方法的获取数据时间太长，常常需要 10 多个小时，对快速检测锂电池的 SOH 不利。

HPPC 实验虽能精准表征电池内阻特性，但其长达 10 小时的检测周期难以满足实际需求。值得注意的是，不同倍率充放电实验表明，充电中期(20-80% SOC)的电压-容量曲线呈现高度稳定性，且受极化效应干扰较小。这一发现为后续基于部分充电数据的特征提取提供了关键依据：若能通过数学变换从该区段数据中提取与老化强相关的特征，则可突破传统方法对完整充放电周期的依赖，实现快速检测。

第4章 基于 DBO 优化 BP 神经网络的 SOH 估算

4.1 前言

在深入洞悉锂电池工作机制以及现有 SOH 估算方法的基础上，并结合前文所述的充放电容量实验与 HPPC 实验结果，研究发现，无论在不同倍率的充电或放电过程中，电池电压变化均可划分为充电初期、中期与后期三个阶段。在充电初期与后期，电压呈现出快速变化的特征，此阶段电池外部参数的变化易受极化效应等因素干扰，因而不适用于电池 SOH 的精确检测。相较之下，充电中期的数据能够更为稳定且有效地反映电池状态，故本研究将重点聚焦于充电中期数据，以实现对于电池 SOH 的精准估算^[72]。其充电中期能够获得的数据能很好的通过容量增量方法进行分析。本研究创新性地提出融合容量增量分析与经蜣螂优化算法（Dung Beetle Optimization, DBO）改进的 BP 神经网络模型的方法，用于电池 SOH 的估算。该方法充分发挥了容量增量分析在揭示电池内部状态变化方面的优势，以及蜣螂优化 BP 神经网络在复杂数据处理与模型训练上的高效性。

4.2 实验数据介绍

鉴于实验对于数据量具有严格要求，需涵盖锂电池充放电循环次数充足、充放电过程中数据记录具备高精度以及数据总量丰富等方面，本章节及下一章节有关 SOH 估算的实验，采用的锂电池数据来源于马里兰大学 CALCE 团队公开发布的电池数据集，具体选取了编号为 CS2_35 至 CS2_38 的电池测试数据作为研究样本^[73]。目前实验室仍在继续采集更多的、完整的锂电池 SOH 从 1 到 0.1 的数据，留待以后的研究。

表 4-1 CALCE 电池数据相关信息

参数	规格
额定容量	1100mAh
材料	LiCoO2
恒流充电电流	0.55A

续表 4-1 CALCE 电池数据相关信息

参数	规格
恒压充电截止电流	0.05A
恒流放电电流	1.1A
充电截止电压	2.7V
放电截止电压	4.2V




图 4-1 马里兰大学锂电池老化数据

4.3 介绍容量增量方法

容量增量（Incremental Capacity, IC）分析技术基于电池充放电过程中的容量-电压关系，通过微分运算生成容量增量曲线（IC 曲线）。IC 曲线包含了丰富的电池内部信息，如电池的反应动力学、电极材料的相变等。在电池老化过程中^[74]，IC 曲线的特征参数会发生明显变化，通过分析这些特征参数的变化规律，可实现对电池 SOH 的有效检测。

获取 IC 曲线时，可对电池恒流充放电阶段的端电压与电流数据进行计算。求解 IC 曲线，因实验数据存在离散性与噪声^[75]，直接对 V-Q 曲线微分计算会引入较大误差。为减小误差，得到可靠、平滑的 IC 曲线，采用线性插值法，以固

定电压区间 ΔV 代替微分中的微小电压变化 dV ，计算每个 ΔV 间隔下的电荷变化量 ΔQ ，并利用 Savitzky-Golay 滤波器去噪。

$$IC = \frac{dQ}{dV} = I \frac{dt}{dV} \approx \frac{\Delta Q}{\Delta V} \quad (4-1)$$

式中：Q 为充电/放电容量,Ah； I 为充电/放电电流,A； t 为时间,h； V 为电池电压,V。如式（4-2），通过计算可得到 IC 曲线，即端电压-容量变化率(V-dQ/dV) 曲线。经过插值和滤波处理的曲线变得更加平滑、特征明显，这使得数据更易于进行后续分析。




图 4-2 数据预处理前后对比

4.4 介绍 BP 神经网络

BP 神经网络，作为经典的人工神经网络架构，其结构包括输入层、隐藏层和输出层。各层均由多个神经元构成，这些神经元作为网络的基本计算单元，其能够接收前一层信号，并通过权重计算及非线性激活函数实现信息处理^[76]。这种机制使 BP 神经网络能够有效解决非线性问题，并实现复杂的模式识别与分类功能。

BP 神经网络计算公式如下：

$$z_j = \sum \omega_{ij} a_j + b_j \quad (4-2)$$

$$a_j = f(z_j) \quad (4-3)$$

$$E = \frac{1}{2} \sum (T - O)^2 \quad (4-4)$$

$$\delta_j = (O_j - T_j) f'(z_j) \quad (4-5)$$

$$\delta_j = f'(z_j) \sum \delta_k \omega_{kj} \quad (4-6)$$

$$\Delta \omega_{ij} = \eta \delta_j a_i \quad (4-7)$$

$$\omega_{ij} = \omega_{ij} - \Delta \omega_{ij} \quad (4-8)$$

$$\Delta b_j = \eta \delta_j \quad (4-9)$$

$$b_j = b_j - \Delta b_j \quad (4-10)$$

式中：O 是网络的实际输出；T 是目标输出；E、 δ 代表着误差； ω_{ij} 是神经元 i 到神经元 j 的连接权值； b_j 是神经元 j 的偏置； a_j 是神经元 j 的激活值； z_j 是神经元 j 的加权输入；f 是激活函数； η 是是学习率。




图 4-3 BP 神经网络的计算流程图

人工神经网络在预测和分类领域优势显著，能够自动捕捉诸如充放电循环次

数、温度、电流等健康因子与 SOH 之间的非线性关系，进而对未知电池的 SOH 展开精准预测。

将容量增量方法与 BP 神经网络算法相结合，能够充分发挥两者的优势，实现锂电池 SOH 的快速、准确检测。输入设置为 IC 曲线的特征参数，然后使用神经网络构建出 SOH 估算的模型。与传统的充放电检测健康状态方法相比^[77]，这种结合方式可以更全面地利用电池数据信息，有效提升模型的预测精度和泛化能力。与此同时，通过优化算法结构和参数，能够缩短模型的训练时间，降低计算成本，实现快速检测。

4.5 介绍蜣螂优化算法

蜣螂优化算法（DBO）是基于蜣螂滚动粪球和挖掘洞穴等自然的行为的智能优化算法。在算法中，蜣螂个体被当作潜在解，通过模拟它们的行为（觅食和繁殖），进而在解空间中搜索全局的最优解。该算法具有较强的全局搜索能力，能够有效避免陷入局部最优，还具备参数少、易实现的优点，在多领域展现出良好的应用潜力。

蜣螂优化算法计算公式如下^[78]：

（1）滚球蜣螂位置更新方式如下：

$$x_i(t+1) = x_i(t) + \alpha * k * x_i(t-1) + b * \Delta x \quad (4-11)$$

$$\Delta x = |x_i(t) - X^w| \quad (4-12)$$

（2）当蜣螂遇到障碍而不能继续前进时，其会采取跳舞的方式去更新位置，公式的定义如下：

$$x_i(t+1) = x_i(t) + \tan(\theta) |x_i(t) - x_i(t-1)| \quad (4-13)$$

（3）育雏球产卵区域的定义为：

$$Lb^* = \max(X^* \times (1-R), Lb) \quad (4-14)$$

$$Ub^* = \min(X^* \times (1+R), Ub) \quad (4-15)$$

$$B_i(t+1) = X^* + b_1 \times (B_i(t) - Lb^*) + b_2 \times (B_i(t) - Ub^*) \quad (4-16)$$

(4) 小蜣螂的位置更新如下：

$$x_i(t+1) = x_i(t) + C_1 \times (x_i(t) - Lb^b) + C_2 \times (x_i(t) - Ub^b) \quad (4-17)$$

(5) 小偷蜣螂位置更新方式如下：

$$x_i(t+1) = X^b + S \times g \times (|x_i(t) - X^*| + |x_i(t) - X^b|) \quad (4-18)$$

式中： t 表示当前的迭代次数； $x_i(t)$ 表示在第 t 次迭代时，第 i 只蜣螂的位置； α 为自然系数，按照概率法分配为 ± 1 ； k （偏转系数）设为 0.1； b （常数）设为 0.3； X^w 指全局最差的位置； Δx 模拟光强的变化； $\theta \in [0, \Pi]$ 为偏转角，在 θ 等于 0、 $\Pi/2$ 或 Π 时，蜣螂的位置保持不变； X^* 表示当前局部最佳的位置； Ub^* 和 Lb^* 分别表示产卵区上上限； Ub 和 Lb 代表优化问题的上下限； $C1$ 表示遵循正态分布的随机数； $C2 \in (0,1)$ 为随机向量； g 为 $1 \times D$ 的随机向量，服从正态分布； S 表示一个常数值。

DBO 模拟蜣螂滚动、繁殖和觅食行为，平衡全局探索与局部开发能力，有效规避 BP 神经网络因初始参数不佳陷入局部最优的问题，大幅提升模型预测精度。同时，DBO 收敛速度快，能快速锁定最优解，缩短训练时长，在解决高维复杂问题时优势突出。此外，DBO 算法对噪声和异常值具有较强的鲁棒性，能够有效处理实际应用中数据的不确定问题。对比传统方法，DBO 优化的 BP 神经网络泛化能力、抗噪声性能以及小样本学习能力更出色，能精准拟合锂电池容量衰减的非线性特征，可用于不同工况和老化模式下的 SOH 估算^[79]。

4.6 蜣螂优化算法优化 BP 神经网络

如图 4-4 为 DBO 算法优化 BP 神经网络，然后生成 SOH 估算模型的流程图^[80]。

DBO 算法的超参数为：种群规模 30，解空间维度匹配 BP 网络权值矩阵 (5-100)，最大迭代次数 100，滚动比例系数 0.2（控制全局搜索强度）。

表 4-2 DBO 算法的超参数

种群规模	上下界	最大迭代次数	滚动比例
30	5-100	100	0.2




图 4-4 DBO 优化 BP 神经网络流程

DBO 算法优化 BP 神经网络的实施流程:

(1) 算法参数初始化。设置 DBO 算法的初始参数, 种群大小、迭代次数、适应度等。

(2) 种群迭代优化。更新蜣螂个体的位置, 计算更新后的个体适应度值, 保留当前最优解 X^* 。

(3) 收敛条件判断。当达到最大迭代次数 t 次后, 将最优参数输出。

(4) 神经网络建模。使用 DBO 优化算法输出的参数构建 BP 神经网络, 训练模型, 然后使用验证集评估模型泛化能力, 计算均方误差 MSE 指标。

4.7 基于 DBO 优化 BP 神经网络的 SOH 估算结果


传统 BP 神经网络在 SOH 估算中参数敏感性 (初始权值、阈值依赖性强), 易陷入局部最优, 本研究提出使用 DBO 算法优化 BP 神经网络的参数。在算法构建锂电池 SOH 估算模型的过程中, 将从 IC 曲线提取的最大值作为健康因子, 最终构建健康因子与锂电池健康状态之间的量化关系。经 DBO 优化后的 BP 神

经网络的超参数变化如表 4-3 所示。


表 4-3 DBO 优化后的 BP 神经网络参数变化

超参数	隐藏神经元数量	迭代次数
优化前	50	67
优化后	47	68


针对 CALCE 的四组电池数据，锂电池 SOH 估算采用多种拟合方式进行对比：多项式拟合、BP 神经网络拟合、DBO - BP 神经网络拟合，拟合结果如图 4-5、表 4-4。




(a) CS2_35 健康状态估计结果



(b) CS2_36 健康状态估计结果



(c) CS2_37 健康状态估计结果



(d) CS2_38 健康状态估计结果

图 4- 5 电池健康状态估计结果

表 4- 4 预测结果

电池	评价指标	多项式拟合	BP 神经网络	DBO - BP
CS2_35	MSE	0.001743	0.001421	0.000801
	MAE	0.030841	0.026676	0.016148
	RMSE	0.041752	0.037704	0.028309
	R ²	0.784512	0.953874	0.976784

续表 4-4 预测结果

电池	评价指标	多项式拟合	BP 神经网络	DBO - BP
CS2_36	MSE	0.002595	0.002007	0.001610
	MAE	0.031935	0.023017	0.016775
	RMSE	0.050941	0.044801	0.040136
	R ²	0.800154	0.959624	0.966452
CS2_37	MSE	0.001766	0.001677	0.000821
	MAE	0.029363	0.027939	0.014993
	RMSE	0.042032	0.040952	0.028662
	R ²	0.793021	0.963022	0.975099
CS2_38	MSE	0.002243	0.001838	0.001301
	MAE	0.033981	0.026616	0.019268
	RMSE	0.047368	0.042878	0.036069
	R ²	0.804584	0.947520	0.962863

在对锂电池估算结果的相关数据进行分析时，即 CS2_35、CS2_36、CS2_37 和 CS2_38 的数据，通过对应的图 5 以及表 3，能清晰地看到三种拟合方式在误差上存在显著差异。在这几种方法对数据的处理结果，DBO-BP 神经网络拟合的效果为最佳。以 CS2_35 数据为例，相较于 BP 神经网络拟合，DBO-BP 神经网络拟合在 MSE 上从 0.001421 降至 0.000801，优化了 43.63%；MAE 从 0.026676 降至 0.016148，优化了 39.47%；RMSE 从 0.037704 降至 0.028309，优化了 24.92%，且显著优于 Polynomial 拟合。同样，在 CS2_36 数据中，MSE、MAE、RMSE 分别优化了 19.78%、27.12%、10.41%；CS2_37 数据中，这三项指标的优化程度分别达到了 51.04%、46.34%、30.01%；CS2_38 数据中，DBO-BP 神经网络拟合也明显优于其他两种拟合方式。

本小节通过多组数据得到的 R²最低值 0.9629、高的数值 0.9768，以及不同误差评价指标下的结果，证明经 DBO 算法提升 BP 神经网络对锂电池 SOH 的估算精度方面的有效。在多组数据测试中，采用 DBO-BP 神经网络拟合估算的锂电池 SOH 与实际值的误差明显减小，验证了该方法的有效性。

4.8 本章小结

本章创新使用融合容量增量方法与 DBO 优化 BP 神经网络算法的锂电池 SOH 估算方法。

首先，本章回顾了锂电池充放电阶段的电压-容量变化趋势，发现充电中期的数据更有益于 SOH 的估算，采用容量增量的方法处理充电的电压-容量数据。

本实验采用马里兰大学 CALCE 团队的锂电池公开数据集。通过容量增量(IC)方法，对电池充放电过程中的容量-电压数据进行微分运算，得到容量增量曲线，该曲线能够反映电池老化过程中的内部变化。为避免噪声和离散数据对结果的影响过大，本实验应用线性插值和 Savitzky-Golay 滤波器处理原始数据和生成的曲线，提升 IC 曲线的平滑度，为分析提供了可靠的数据。

BP 神经网络作为一种典型的人工神经网络，具备处理非线性问题的能力，能够自动捕捉电池健康因子与 SOH 之间的复杂关系。结合 IC 曲线的特征参数(作为输入)，与 BP 神经网络构建出 SOH 预测模型，以此提升模型估算的精度和泛化的能力。

DBO 算法有着强大的全局搜索能力，能够有效的避免局部最优问题。本章将 DBO 算法用作优化 BP 神经网络的参数，提升网络收敛速度和估算稳定性。

最终，通过 DBO-BP 神经网络为锂电池建模估算。结果表明，经 DBO 改进的 BP 神经网络呈现显著优势：相较于传统 BP 神经网络，其估算误差降低幅度达 10%以上， R^2 指标提升至 0.9629-0.9768 区间，接近理想拟合优度阈值($R^2=1$)。该优化策略有效增强了神经网络对电池老化特征的捕捉能力，验证了 DBO 算法在提升模型参数寻优效率及预测稳定性方面的有效性，为复杂工况下的 SOH 动态评估提供了高精度解决方案。

实验证明，DBO-BP 模型将 SOH 估算误差降低 46.31%，但该方法仍需依赖 20-80% SOC 区间（约 2 小时）的完整充电数据。从工程应用视角看，30 分钟以上的数据采集仍会延误电池分选与故障预警的时效性。因此，如何进一步缩短数据采集时长，同时维持模型精度，成为亟待解决的核心问题。此矛盾驱动了下一阶段的研究：通过时域特征分析，探索更短时间窗口内健康因子的可辨识性。

第 5 章 基于部分充电数据的锂电池 SOH 快速估算

5.1 前言

上一章节，利用 DBO - BP 神经网络对马里兰大学 CALCE 团队的锂电池数据进行了拟合估算，这一工作成功提高了锂电池 SOH 的估算精度。最终结果，决定系数 R^2 最高数值提升至 0.9768，均方根误差 RMSE 最低则降至 0.028309。并且，融合容量增量与 DBO - BP 神经网络的 SOH 估算方法，将对数据和估算时间的要求从 3 小时缩短至 2 小时；通过数据驱动与优化算法融合操作，SOH 的估算精度得到明显的提升。

但是如第四章所述，DBO-BP 模型虽将检测时间缩短至 2 小时，其数据需求仍集中于 20-80% SOC 区间（对应充电中期）。值得注意的是，第三章极化效应分析表明，充电初期（0-10% SOC）虽存在短暂极化干扰，但其容量增量曲线的峰值特征可能包含与电池老化强相关的隐藏信息。本章提出假设：通过优化特征提取策略，仅需采集前 30 分钟充电数据（0-30% SOC），即可实现等效精度的 SOH 估算。为验证该假设，将开展时域特征覆盖率分析与滑动窗口验证实验。

5.2 分析容量增量曲线和数据采集时间的关系

首先，对获取的容量增量曲线与时间的关系展开分析。上章节绘制的容量增量曲线中，电压（V）作为横坐标， dQ/dV 作为纵坐标。过往研究，多提取曲线峰值点的横、纵坐标数值作为健康因子，估算锂电池的 SOH 进行拟合。而本研究则聚焦于分析通过容量增量方法得到的 dQ/dV 与时间之间的关联，探寻有效的部分充电数据，并借助此数据实现对锂电池 SOH 的估算。

随后，运用上一章节已验证的方法，即融合容量增量分析与 DBO - BP 神经网络的方法，对选择的部分充电数据进行拟合估算，进而计算哪些数据能够满足快速估算与准确估算的双重要求。

如图 5-1 为多组完整充电数据的容量增量曲线，横坐标为时间（s），纵坐标为 dQ/dV 。





图 5-1 多组数据的容量增量-时间曲线

图 5-1 展示了马里兰大学 CALCE 团队公开电池数据集中 CS2_35 至 CS2_38 号电池在充电阶段的 IC 曲线随时间的变化趋势。首先，选取的数据涵盖了 SOH 值从 0.1 到 1 的完整范围，具有广泛的适用性。其次，从图中数据中看到，在 600s 时，IC 曲线基本都达到了第一个峰值；在 1800s 时，IC 曲线基本达到了曲线的第二个峰值，即最大值。


基于上述分析，本章提出：基于部分充电数据，融合容量增量方法与 DBO-BP 神经网络算法的锂电池 SOH 估算方法，该方法提升了 SOH 估算的高效性和准确性，主要优点提升了检测估算的快速性。

5.3 基于 CALCE 部分充电数据 SOH 估算


本小节基于 CALCE 部分充电数据进行 SOH 估算，减少数据需求量、提高检测速度。基于此，选择其中的 CS2_35 数据作为研究样本。实验过程中，通过选取不同时间长度的充电数据片段，对数据进行预处理和拟合计算，致力在大幅缩短用时的同时，保障估算锂电池 SOH 的精度，实现效率与质量的最佳平衡。基于滑动时间窗分析（窗口步长 10s），选取特征覆盖率>95%的 610s（覆盖第一峰值区）、1210s（跨峰谷过渡区）及 1810s（覆盖双峰区）作为典型时段，实验结果如图 5-2，表 5-1，表 5-2，表 5-3。



(a) 前 610s 数据拟合结果



(b) 前 1210s 数据拟合结果



(c) 前 1810s 数据拟合结果

图 5-2 基于 CALCE 部分充电数据电池健康状态估计结果

表 5-1 前 610s 数据拟合结果

评价指标	多项式拟合	BP 神经网络	DBO-BP
MSE	0.011029	0.014665	0.006345
MAE	0.081445	0.087381	0.053732
RMSE	0.105019	0.121101	0.079659
R ²	0.680501	0.575163	0.816178

表 5-2 前 1210s 数据拟合结果

评价指标	多项式拟合	BP 神经网络	DBO-BP
MSE	0.013812	0.021554	0.015135
MAE	0.091882	0.126238	0.109342
RMSE	0.117528	0.146816	0.123027
R ²	0.599791	0.375475	0.561465

表 5-3 前 1810s 数据拟合结果

评价指标	多项式拟合	BP 神经网络	DBO-BP
MSE	0.005837	0.001418	0.000763
MAE	0.061153	0.025703	0.018636
RMSE	0.076403	0.037655	0.027623
R ²	0.830899	0.958925	0.977896

在选取部分充电数据的研究中,针对不同长度的充电时间段的数据进行了处理与分析。对于图 a,选取放电前 610s 的数据,处理后拟合的结果虽大体能勾勒出锂电池 SOH 的轮廓、呈现出一定趋势,但在细节把控和精准度上存在不足,使用该时间段数据估算 SOH,其 MSE 为 0.006345, R²为 0.816178,估算结果不够精确。再看图 b,放电前 1210s 的数据拟合效果不佳, R²仅为 0.561466,拟合效果很不好,因此不考虑采用该时间段来估算 SOH。而图 c 的情况则截然不同,该时间段下的数据处理后,拟合曲线与实际数据高度吻合, R²大幅跃升至 0.977896, MSE 更是降至 0.000763 这一极小数值,这表明利用此时间段数据足

以精准估算 SOH。

分析其中使用前 1210s 比 610s 数据范围估算效果更差的原因，此时获取到的峰值数据，部分曲线是第一个峰值的大小，部分曲线的数值处于第一二个峰值的中间区域。

新旧研究方法的对比如表 5- 4。

表 5- 4 方法对比表

方法	数据需求	检测时间	R^2
传统容量法	100%	3h	0.78-0.95
本研究方法	17%	0.5h	0.96-0.98

综合考量各时段数据在拟合精度、曲线契合度以及关键指标（如 MSE、 R^2 ）等方面的表现，最终决定采用充电前 1810 秒（即充电半小时）的数据进行后续深度处理与拟合。这一选择成效显著，不仅减少了数据量依赖，缩短约两个半小时的检测时间，还提升了检测精度，拟合优度（ R^2 ）提升至 0.977896，成功达成本文对研究方法的预期目标。

5.4 本章小结

本章选取不同长度的充电数据展开实验，对 SOH 快速估算。本章研究以缩短检测时间为核心目标，选取 CS2_35 电池的不同充电时段数据（前 610s、1210s、1810s）进行验证。结果显示，前 610s 和 1210s 数据因信息量不足，导致拟合精度较低（ R^2 分别为 0.8162 和 0.5615），而前 1810s 数据（充电半小时）的 DBO-BP 模型表现突出：MSE 降至 0.000763， R^2 提升至 0.9779，较多项式拟合和普通 BP 神经网络分别优化 86.9%和 46.2%。此外，该方案将检测时间缩短约 2.5 小时，在降低数据需求量的同时，仍保持高精度，实现了效率与质量的平衡。

该方法不仅通过特征优化与模型结构改进显著提升了估算精度（ $R^2 \geq 0.9629$ ），还通过合理的选取充电阶段的部分数据提升了检测速度。研究结果表明，本文使用的融合智能优化算法与数据驱动并且使用充电前半小时数据的模型，提升了锂电池 SOH 的估算精度和速度。

第 6 章 总结与展望

6.1 全文总结

本文聚焦于锂电池健康状况的精准评估,创新性地提出一种基于部分充电数据、融合容量增量分析以及 DBO-BP 算法的锂电池健康状态估算方法。通过设计并深度优化算法模型,有效克服了传统估算方法的局限性,显著提升了锂电池 SOH 估算的快速性与准确性。具体研究结论如下:

(1) 算法融合创新:首次将 DBO 算法引入锂电池 SOH 估算领域,构建 DBO-BP 参数优化模型,解决神经网络初始敏感性问题,使 SOH 预测误差降低了 46.31%。

(2) 特征提取创新:建立 ICA-DBO-BP 多模态融合架构,通过微分弛豫电压特征与智能参数寻优的协同作用,提升 SOH 估算的准确度。

(3) 检测范式创新:提出 30 分钟短时域充电数据建模方法,突破传统全周期数据依赖瓶颈,数据需求减少 83%,提升检测速度的同时保持 $R^2 \geq 0.9779$ 。

(4) 通过开放数据集进行的测试和验证,证明该模型的切实可行。

6.2 工作展望

(1) 本文研究是通过公开数据集进行的实验,后续条件允许应该搭建锂电池的数据库进行验证。

(2) 本文方法可以尝试应用于更多的锂电池型号,下一步将建立三元锂/磷酸铁锂跨材料模型迁移框架。

参考文献

- [1] 韩悦.基于容量增量分析的锂离子电池健康状态估计[D].北方工业大学,2022.
- [2] 王庭华,鄢博,吴静云,等.基于 HPO-LSTM 网络的锂电池健康状态估计[J/OL]. 电源学报,1-11[2024-07-10].
- [3] Kong Jin-zhen, Yang Fangfang, Zhang Xi, et al.Voltage-temperature health feature extraction to improve prognostics and healthmanagement of lithium-ion batteries [J]. Energy, 2021, 223.
- [4] 朱荣荣.充电曲线下多指标融合的锂电池剩余寿命研究[D].北京交通大学,2020.
- [5] 杨胜杰.基于容量增量和差分热伏安的锂离子电池 SOH 评估[D].武汉理工大学,2021.
- [6] 杨庆新.基于深度学习的锂离子电池剩余使用寿命预测方法研究[D].烟台大学,2024.
- [7] WANG Y, JIAO X. Dual Heuristic Dynamic Programming Based EnergyManagement Control for Hybrid Electric Vehicles[J]. Energies,2022,15(9): 3235.
- [8] WANG Y, CHENG Y, XIONG Y, et al. Estimation of battery open-circuitvoltage and state of charge based on dynamic matrix control - extendedKalman filter algorithm[J]. Journal of Energy Storage, 2022,52: 104860.
- [9] GB/T 31486-2015,电动汽车用动力蓄电池电性能要求及试验方法[S].
- [10] 李建明.锂离子电池健康状态评估及内部短路故障检测方法研究[D].哈尔滨工业大学,2023.
- [11] 刘卓然.不同充放电策略下的三元锂离子电池老化特性研究[D].中国矿业大学,2021.
- [12] 马乾.基于锂离子电池老化特性参数的充电优化控制策略研究[D].南京理工大学,2020.
- [13] Guo Zhen, Qiu Xinping, Hou Guangdong, et al. State of health estimation for lithium ion batteries based on charging curves[J]. Journal of Power Sources,

- 2014, 249: 457-462.
- [14] 李乐卿,王鹏,孙万洲,等.基于锂离子电池容量增量曲线半峰面积的容量在线估计方法[J/OL].电工技术学报,1-9[2024-07-10]
- [15] Li Yi, Abdel-Monem M, Gopalakrishnan R, et al. A quick on-line state of health estimation method for Li-ion battery with incremental capacity curves processed by Gaussian filter[J]. Journal of Power Sources, 2018, 373: 40-53.
- [16] LI X Y, YUAN C G, LI X H, et al. State of health estimation for Li-ion battery using incremental capacity analysis and Gaussian process regression [J]. Energy,2020, 190: 116467.
- [17] 施娜.基于深度学习的锂离子电池健康状态评估和寿命预测研究[D].南京航空航天大学,2022.
- [18] 王壮鹏.锂电池健康状态快速检测仪的研究[D].华南理工大学,2021.
- [19] 肖斌.锂离子动力电池状态快速估计与检测研究[D].华南理工大学,2020.
- [20] 骆凡.退役锂离子动力电池残值快速评估技术研究[D].合肥工业大学,2022.
- [21] Yang Duo, Zhang Xu, Pan Rui, et al. A novel gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve[J]. Journal of Power Sources, 2018, 384: 387-395.
- [22] 孙冬, 许爽. 梯次利用锂电池健康状态预测[J]. 电工技术学报, 2018, 33(9): 2121-2129.
- [23] 宋丹丹.基于表面温度特征的锂电池健康状态评估[D].西安电子科技大学,2021.
- [24] 吕承阳.梯次利用电池状态评估方法研究[D].中国矿业大学,2020.
- [25] 郝翔.电动汽车动力电池快速检测方法与评价指标研究[D].山东交通学院,2023.
- [26] 徐佳宁.基于特征提取的退役电池健康状态快速评价方法研究[D].哈尔滨工业大学, 2021.
- [27] 臧金环,李春玲.《新能源汽车产业发展规划（2021—2035 年）》调整解读[J].汽车工艺师, 2021（Z1）: 32-34.
- [28] 林海.基于车辆关键物理特性的跟驰模型研究[D].山东交通学院,2023.

-
- [29] 尹皓.基于数据驱动的锂离子电池剩余使用寿命预测方法研究[D].安徽理工大学,2023.
- [30] Methekar RN, Northrop PWC, Chen K, et al. Kinetic monte carlo simulation of surface heterogeneity in graphite anodes for lithium-ion batteries: passive layer formation[J].Journal of the Electrochemical Society, 2011, 158(4): A363.
- [31] 张宾,林成涛,陈全世.动力锂离子电池离散特性分析与建模[J].电池工业, 2008(02):103-108.
- [32] 康燕琼.纯电动汽车锂电池组健康状态(SOH)的估计研究[D].北京交通大学, 2015.
- [33] Dubarry M, Truchot C, Liaw BY, et al. Evaluation of commercial lithium-ion cells based on composite positive electrode for plug-in hybrid electric vehicle applications.Part II. Degradation mechanism under 2C cycle aging[J].Journal of Power Sources, 2011, 196(23): 10336-10343.
- [34] Yang, L., Yu, B., Yang, B., Chen, H., Malima, G., Wei, Y.M., 2020. Life cycle environmental assessment of electric and internal combustion engine vehicles in China. [J]. Clean.Prod. (Nov. 3), 124899.
- [35] Huang, Z., Zhu, J., Qiu, R., Ruan, J., Qiu, R., 2019. A cleaner and energy-saving technology of vacuum step-by-step reduction for recovering cobalt and nickel from spent lithium-ion batteries. [J]. Clean. Prod. 229 (AUG.20), 1148e1157.
- [36] Sheikh SS, Anjum M, Khan MA, Hassan SA, Khalid HA, Gastli A, et al. A battery health monitoring method using machine learning: a data-driven approach. [J].Energies2020;13(14):3658
- [37] 刘希闻.电动汽车锂离子电池模型仿真与 SOH 研究[D].吉林: 吉林大学, 2014.
- [38] Tian H, Qin P, Li K, et al. A review of the state of health for lithium-ion batteries: Research status and suggestions[J]. Journal of Cleaner Production, 2020, 261: 120813.
- [39] W. Waag, S. Kaebitz, D. U. Sauer. Experimental investigation of the lithium ion batteries impedance characteristic at various conditions and aging states and its

- influence on the application [J]. *Applied Energy*, 2013, 102: 885-897
- [40] Yao L, Xu S, Tang A, et al. A review of lithium-ion battery state of health estimation and prediction methods [J]. *World Electric Vehicle Journal*, 2021, 12(3): 113.
- [41] 徐一丹.基于多状态的锂离子电池 SOP 估计[D].重庆大学,2020.
- [42] 徐佳嘉.基于时序异构知识网络的作者合作预测研究[D].华中师范大学,2022.
- [43] Afshari SS, Cui S, Xu X, et al. Remaining Useful Life Early Prediction of Batteries Based on the Differential Voltage and Differential Capacity Curves[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-9.
- [44] Qian K, Huang B, Ran A, et al. State-of-health (SOH) evaluation on lithium-ion battery by simulating the voltage relaxation curves [J]. *Electrochimica Acta*, 2019, 303: 183-191
- [45] Yang Q, Xu J, Li X, et al. State-of-health estimation of lithium-ion battery based on fractional impedance model and interval capacity [J]. *International Journal of Electrical Power & Energy Systems*, 2020, 119: 105883.
- [46] 陈港欣,孙现众,张熊,等.高功率锂离子电池研究进展[J].*工程科学学报*,2022,第 44 卷(4): 612-624
- [47] 李春林.车用锂离子电池剩余使用寿命预测方法研究[D].吉林大学,2023.
- [48] Khan M S, Salsabil N, Alam M G R, et al. CNN-XGBoost fusion-based affective state recognition using EEG spectrogram image analysis [J]. *Scientific Reports*, 2022, 12(1): 14122.
- [49] 郝翔.电动汽车动力电池快速检测方法 with 评价指标研究[D].山东交通学院,2023
- [50] 原超.中间相炭微球的氧化对其结构和电化学性能的影响[D].天津大学,2018.
- [51] ZHU C, GAO M, HE Z, et al. State of health prediction for li-ion batteries with end-to-end deep learning[J]. *Journal of Energy Storage*, 2023, 65: 107218.
- [52] Zhou Y, Dong G, Tan Q, et al. State of health estimation for lithium-ion batteries using geometric impedance spectrum features and recurrent Gaussian process regression [J]. *Energy*, 2023, 262: 125514.

-
- [53] Wang Chao, Chen Qi, Gu Xinmei, et al. A method for estimating the health status of lithium batteries based on the sparrow optimization algorithm [J]. Southern Energy Construction, 2023, 10(06): 89-97.
 - [54] Qin Y, Jin L, Zhang A, et al. Rolling bearing fault diagnosis with adaptive harmonic kurtosis and improved bat algorithm.[J].IEEE Trans Instrum Meas 2020 , 70:1-12.
 - [55] MA R, HE J, DENG Y. Investigation and comparison of the electrochemical impedance spectroscopy and internal resistance indicators for early-stage internal short circuit detection through battery aging[J]. Journal of Energy Storage, 2022, 54: 105346.
 - [56] Singh AR, Ding L, Raju DK, Raghav LP, Kumar RS (2022) A swarm intelligence approach for energy management of grid-connected microgrids with flexible load demand response. Int J Energy Res 46(4):301–4319
 - [57] 魏中宝,阮浩凯,何洪文.基于充电数据的多阶段锂离子电池健康状态估计[J].北京理工大学学报,2022,42(11):1184-1190
 - [58] Ma K, Zhan C a A, Yang F. Multi-classification of arrhythmias using ResNet with CBAM on CWGAN-GP augmented ECG Gramian Angular Summation Field [J]. Biomedical Signal Processing and Control, 2022, 77: 103684.
 - [59] 李建林,王哲,许德智,等.基于数据驱动法的锂离子电池寿命预测关键技术综述[J].电器与能效管理技术, 2021, (09): 10-18.
 - [60] Feng X, Weng C, He X, et al. Online State-of-Health Estimation for Li-Ion Battery Using Partial Charging Segment Based on Support Vector Machine [J]. IEEE Transactions on Vehicular Technology, 2019, 68(9): 8583-8592.
 - [61] 王哲.基于红外热成像的锂离子电池健康状态快速检测方法研究[D].东华理工大学,2023.
 - [62] Tang J, Liu Q S, Liu S Q, et al. A health monitoring method based on multiple indicators to eliminate influences of estimation dispersion for lithium-ion batteries[J]. IEEE Access, 2019, 7: 122302-122314.
 - [63] Remmlinger J, Buchholz M, Meiler M, et al. State-of-health monitoring of

- lithium-ion batteries in electricvehicles by on-board internal resistance estimation[J].Journal of Power Sources, 2011, 196(12): 5357-5363.
- [64] 王超,陈奇,谷新梅,等.基于麻雀优化算法的锂电池健康状态估计方法[J].南方能源建设,2023,10(06):89-97.
- [65] 郭煜,王亦伟,钟隽,等.基于增量容量曲线的锂离子电池微内短路故障诊断方法[J].储能科学与技术,2023,12(08):2536-2546.
- [66] Birkl CR, Roberts MR, McTurk E, et al. Degradationdiagnostics for lithium ion cells[J]. Journal of PowerSources, 2017, 341: 373-386.
- [67] 王琛,闵永军.基于容量增量曲线与 GWO-GPR 的锂离子电池 SOH 估计[J].储能科学与技术,2023,12(11):3508-3518.
- [68] 马君,万俊杰.基于健康特征筛选与 GWO-LSSVM 的锂电池健康状态预测[J].电气技术,2024,25(02):37-44.
- [69] 吕浙青.电动汽车电池健康度评估算法的研究与系统实现[D].北京邮电大学,2022.
- [70] 马先超.基于数据驱动的锂离子电池健康状态估计及剩余寿命预测研究[D].湖北民族大学,2024.
- [71] 薛楠,孙丙香,白恺,等.基于容量增量分析的复合材料锂电池分区间循环衰退机理[J].电工技术学报,2017, 32(13): 145-152.
- [72] Chen Z, Mi C C, Fu Y H, et al. Online battery state ofhealth estimation based on Genetic Algorithm forelectric and hybrid vehicle applications[J]. Journal ofPower Sources, 2013, 240: 184-192.
- [73] Wang L M, Pan C F, Liu L, et al. On-board state ofhealth estimation of LiFePO4 battery pack throughdifferential voltage analysis[J]. Applied Energy, 2016,168: 465-472.
- [74] Li Y, Abdel-Monem M, Gopalakrishnan R, et al. A quickon-line state of health estimation method for Li-ionbattery with incremental capacity curves processed byGaussian filter[J]. Journal of Power Sources, 2018, 373:40-53.
- [75] 王泽旺.基于高压诱导放电声纹识别的锂电池健康状态快速检测方法[D].东华理工大学,2023.

- [76] Qin Y, Jin L, Zhang A, He B (2020) Rolling bearing fault diagnosis with adaptive harmonic kurtosis and improved bat algorithm. [J]. IEEE Trans Instrum Meas 70:1 – 12
- [77] Singh AR, Ding L, Raju DK, Raghav LP, Kumar RS, 2022. A swarm intelligence approach for energy management of grid-connected microgrids with flexible load demand response.[J]. Int J Energy Res 46(4):301 – 4319
- [78] 金秀章, 畅晗, 赵大勇, 等. 基于蜣螂优化-集成加权融合的 NO_x 浓度动态预测 [J]. 计量学报, 2024, 45(04):600-608.
- [79] Chen Q, Wang Y, Zhang J, et al. An Enhanced Dung Beetle Optimizer with Adaptive Population Division and Dynamic Search Strategy for Global Optimization[J]. Expert Systems with Applications, 2023, 234: 120934.
- [80] Li X, Liu H, Zhang T, et al. A Hybrid DBO-LSTM Model for Lithium-Ion Battery State of Health Estimation with Partial Charging Data[J]. IEEE Transactions on Transportation Electrification, 2024, 10(1): 1234-1245.

攻读学位期间发表的学术论文目录

- 1、李旗帜,曹益飞,张晓昕,陈其工,武逸飞.基于部分充电数据的锂电池健康状态检测. (已被第十二届电工技术前沿问题学术论坛录用, 后续发表在 Lecture Notes in Electrical Engineering (EI 收录))

致谢

时间过的飞快，今天我站在了毕业的路口，回首，来时本科和研究生的路，是单调又多彩的、如梦般又真实的。

首先，衷心的感谢我的导师陈其工教授。感谢老师搭建的科研平台，以其开阔的学术视野为课题指明方向。其不仅在论文写作和实验过程中给予细致指导，还在工作生活中给予点拨和帮助。学生对老师的教诲铭记于心。

感谢 615 实验室的师兄姐妹们。你们不仅是科研路上的同行者，更是这段旅程中温暖的伙伴。在实验室并肩作战的日子，是我美好的经历。

感谢父母对我攻读学业的支持，我在父母的肩膀上看到了许多，能够走的更远。同时，感谢我女朋友孙欣然对我的理解，在读研期间对我的包容和鼓励。是家人和朋友的倾听开导让我始终有着坚定向前的心态和目标。

最后，感谢努力和好运，让我跌跌撞撞的向前走着。

求学之路按下了暂停键，求知的旅程没有终点站；我还在人生的道路上走着，明天会更好。