
分类号: TM912

单位代码: 10363

密 级: 公开

学 号: 2220340118

题 目 基于萤火虫优化 GRU 的锂电池健康状态估计
与检测设备研究

题 目 Firefly-Algorithm Optimized GRU for Lithium-ion
Battery SoH Estimation and Testing Equipment

学生姓名: 武逸飞

指导教师: 陈其工 (教授)

专 业: 控制科学与工程

研究方向: 控制理论与控制工程

论文答辩日期: 2025 年 5 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：

日期： 年 月 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： 年 月 日

日期： 年 月 日

基于萤火虫优化 GRU 的锂电池健康状态估计 与检测设备研究

摘 要

锂离子电池健康状态 (State of Health, SoH) 的估计对于电池管理及梯次利用至关重要。然而现有的 SoH 预测方法在数据需求、计算复杂度及预测精度等方面仍存在一定局限性。

本研究采用了一种基于萤火虫算法 (Firefly Algorithm, FA) 优化门控循环单元 (Gated Recurrent Unit, GRU) 的 SoH 估计方法, 并设计了一款高精度双通道 100A 电池测试仪用来获取精准实验数据。首先结合锂电池特性实验分析了锂离子电池的基本结构、工作原理及健康衰退机理, 提取了充电过程中与 SoH 高度相关的特征参数恒流充电时间 (Constant Current Charging Time, CCCT) 与恒压充电时间 (Constant Voltage Charging Time, CVCT)。同时, 为了提高模型的适应性, 提出了一种动态特征选择策略以缩短估计时间。其次, 采用门控循环单元神经网络构建预测模型, 对输入数据进行了奇异值分解降噪等预处理优化输入数据质量, 引入了萤火虫优化算法进行超参数调优以提升模型的全局搜索能力和预测精度。最后, 为了获取锂电池充电数据, 本研究设计了一款双相数字控制电池测试仪。测试仪采用高性能主控芯片, 集成双相同步升降压电路、电流/电压检测电路、驱动电路及系统保护, 并优化控制环路以提升动态响应性能。

实验结果表明，本研究提出的 SoH 估计模型相较于传统方法在预测精度及收敛速度方面均表现更优，使用单一特征输入可缩短完整 SoH 估计时间，验证了所提方法的有效性。电池测试仪经过频率响应分析的环路稳定性测试，验证了单相、双相电流及双相电流-电压控制的精度及鲁棒性。此外，本研究搭建了模拟真实工况的实验平台并验证了测试仪在复杂运行条件下的数据采集能力及系统稳定性。所设计的测试仪能够精准测量电池关键参数，为 SoH 估计提供高质量数据支撑。

关键词：锂电池健康状态；萤火虫算法；门控循环单元；动态特征选择；电池测试仪

Firefly-Algorithm Optimized GRU for Lithium-ion Battery SoH Estimation and Testing Equipment

ABSTRACT

The estimation of the state of health (SoH) of lithium-ion batteries is crucial for efficient battery management and second-life utilization. However, existing SoH prediction methods face limitations in terms of data requirements, computational complexity, and prediction accuracy, making it challenging to balance precision and efficiency in practical applications.

To address these challenges, this paper proposes an SoH estimation method based on a firefly algorithm (FA)-optimized gated recurrent unit (GRU) model and designs a high-precision dual-channel 100A battery testing system to obtain accurate experimental data. Firstly, this study combines experimental analysis to examine the fundamental structure, operating principles, and degradation mechanisms of lithium-ion batteries, extracting key charge process features—constant current charging time (CCCT) and constant voltage charging time (CVCT)—that are highly correlated with SoH. Additionally, to enhance model adaptability and reduce estimation time, a dynamic feature selection strategy is introduced. Secondly, a GRU neural network is employed to construct the prediction

model, where the FA optimization algorithm is used for hyperparameter tuning, improving global search capability and prediction accuracy. Furthermore, singular value decomposition (SVD)-based denoising and other preprocessing techniques are applied to enhance input data quality. Lastly, to obtain high-precision experimental data, a dual-phase 100A battery testing system is developed. The testing system integrates a high-performance main control chip, a dual-phase synchronous Buck-Boost circuit, current/voltage detection circuits, driver circuits, and protection mechanisms, with optimized control loops to improve dynamic response performance.

Experimental results demonstrate that the proposed SoH prediction model outperforms traditional methods in terms of both prediction accuracy and convergence speed, validating its effectiveness. The battery testing system is subjected to loop stability analysis through frequency response tests, verifying the accuracy and robustness of single-phase, dual-phase current, and dual-phase current-voltage control. Additionally, an experimental platform simulating real-world operating conditions is constructed, confirming the system's data acquisition capability and stability under complex working conditions. The designed testing system enables precise measurement of key battery parameters, providing high-quality data support for SoH estimation.

Wu Yi Fei(Control Science and Engineering)

Supervised by Professor Chen Qi Gong

KEY WORDS: Lithium-ion battery State of Health (SoH); Firefly
Algorithm (FA); Gated Recurrent Unit (GRU); Dynamic feature selection;
Battery testing equipment

目录

摘 要.....	I
ABSTRACT.....	III
第 1 章 绪论	1
1.1 本研究的背景及意义.....	1
1.2 研究现状.....	2
1.2.1 锂离子电池 SoH 概述	2
1.2.2 锂离子电池 SoH 估计方法	3
1.2.3 电池检测技术.....	4
1.3 本文研究内容.....	6
第 2 章 锂电池特性分析	8
2.1 锂电池基本构造与工作原理.....	8
2.1.1 锂电池基本构造.....	8
2.1.2 锂电池基本工作原理.....	8
2.2 锂电池特性实验.....	9
2.2.1 实验对象.....	9
2.2.2 实验平台.....	10
2.2.3 混合脉冲功率特性测试实验.....	10
2.2.4 不同倍率充放电实验.....	14
2.3 锂电池健康度衰退分析及特征量选取.....	18
2.3.1 电池老化数据集介绍.....	18
2.3.2 容量衰减的机理分析.....	19
2.3.3 特征量分析与选取.....	20
2.4 本章小结.....	22
第 3 章 基于萤火虫算法优化 GRU 模型的 SoH 估计方法	23
3.1 数据预处理.....	23

3.2 萤火虫优化算法.....	25
3.3 GRU 门控循环单元网络	26
3.4 萤火虫算法优化 GRU 神经网络	28
3.5 结果分析.....	31
3.5.1 SoH 估计实验配置	31
3.5.2 SoH 估计方法验证	32
3.6 本章小结.....	37
第 4 章 电池测试仪设计	38
4.1 测试仪设计目标与需求.....	38
4.2 硬件架构设计.....	38
4.2.1 主控芯片功能与选择.....	40
4.2.2 关键器件选型.....	40
4.3 电路设计.....	42
4.3.1 驱动电路设计.....	42
4.3.2 双相同步 Buck-Boost 电路设计	43
4.3.3 检测电路设计.....	44
4.3.4 保护电路设计.....	47
4.3.5 电源电路设计.....	48
4.4 软件架构与控制环路设计.....	50
4.4.1 软件流程设计.....	51
4.4.2 控制环路设计.....	52
4.5 设备测试.....	52
4.5.1 软件频率响应测试.....	52
4.5.2 实物测试.....	57
4.6 本章小结.....	59
第 5 章 总结与展望	61
5.1 全文总结.....	61
5.2 研究展望.....	62
参考文献.....	63

致谢.....	69
---------	----

第1章 绪论

1.1 本研究的背景及意义

随着全球对清洁能源的需求日益增加，新能源汽车作为推动绿色交通的重要组成部分，正在逐步取代传统燃油汽车，成为了全球汽车工业发展的新方向^[1]。新能源汽车以其低排放、环保和节能的特点，不仅能有效缓解能源危机和环境污染，还为未来的可持续发展提供了新的解决路径。动力锂离子电池作为新能源汽车的核心部件，凭借其高能量密度、长使用寿命和较低的自放电率等优势，成为新能源汽车领域最重要的动力来源之一^[2]。

根据最新数据，2023 年全球锂电池的出货量达到了 1202.6GWh，同比增长 25.6%^[3]。其中，中国市场的出货量为 887.4GWh，占全球总量的 73.8%。2023 年中国动力锂电池的产量为 675GWh，同比增长达到 29.6%^[4]。这一增长趋势反映了中国电池制造业的快速扩张，也显示出中国新能源汽车市场的强劲需求。从 2018 年至 2023 年，中国动力锂离子电池的产量从 2018 年的 50GWh 持续增长至 2023 年的 675GWh，年均增长约为 30%。增长的背后不仅表明国内新能源汽车市场的蓬勃发展，也意味着寿命到期锂电池数量的激增。如何有效管理这些退役电池，尤其是如何回收和再利用这些电池，成为亟待解决的问题。

随着退役电池数量的增加，科学评估电池的健康状态以判断其能否继续使用已然成为电池回收和梯次利用的关键。电池的健康状态评估对于延长电池使用寿命、减少资源浪费和环境污染具有重要意义^[5]。锂电池健康状态的准确估计可以判断电池的剩余寿命、性能衰减程度以及是否适合用于储能系统或其他低功率应用，从而有效提高电池的使用效率，避免资源浪费环境污染^[6]。

为了实现动力锂电池的有效回收与梯次利用，建立高效的电池测试体系显得尤为关键。电池测试仪能够实时监测电池的电压、电流、温度等关键参数，为健康状态估计提供可靠数据。近年来，随着电池管理技术的进步，电池测试仪的设计和优化逐步完善，在退役电池的检测过程中发挥重要作用，用以评估电池是否

适合继续使用，或是否应当进入回收和再生利用的流程。通过高效的电池测试和健康状态检测，电池的生命周期管理得以优化，在资源的利用效率得到提升的同时，降低电池回收过程中对环境的负面影响。

综上所述，动力锂离子电池健康状态估计与检测的研究是新能源汽车产业发展的重要组成部分。通过基于优化算法的深度学习方法，结合精密的电池测试仪，可以大大提高电池健康状态估计的准确性和效率，为电池的回收和再利用提供科学依据，推动新能源汽车产业的可持续发展^[7]。因此，开展锂电池健康状态估计与检测设备的研究不仅具有重要的学术价值，也具有广泛的应用前景。

1.2 研究现状

1.2.1 锂离子电池 SoH 概述

锂离子电池作为现代电力设备的核心部件，广泛应用于电动汽车、便携式电子设备以及储能系统中。随着锂电池使用时间的增加，其性能会逐渐衰退，表现为容量的下降和内阻的增加，电池的健康状态（State of Health, SoH）是评估其性能衰退程度的重要指标^[8]。

常见的锂电池 SoH 定义方法包括基于容量^[9,10]和基于内阻^[11,12]的两种定义方法。基于容量的方法将电池当前的最大可用容量与电池出厂时的最大可用容量进行比较，以百分比形式表示电池的健康状态。其公式为^[13]：

$$SoH = \frac{Q_{aged}}{Q_{rated}} \times 100\% \quad (1-1)$$

其中， Q_{aged} 表示电池当前的最大可用容量， Q_{rated} 为电池出厂时的最大可用容量。通过容量定义的方法，直接反映了电池的容量衰减，适用于评估电池的衰退程度。

另一种基于内阻的定义方法则侧重于通过电池的内阻变化来判断电池的健康状态。随着电池的老化，内阻会逐渐增大，电池的性能也会因此下降。基于内阻的 SoH 定义公式为：

$$SoH = \frac{(R_{EOL} - R_{aged})}{(R_{EOL} - R_{rated})} \times 100\% \quad (1-2)$$

其中, R_{rated} 为电池出厂时的内阻, R_{aged} 为电池当前的内阻, R_{EOL} 为电池的寿命终止点内阻。该方法能够有效反映电池的老化过程, 但对测量设备的精度要求较高且数据难以获取, 因此在实际应用中较少使用。

1.2.2 锂离子电池 SoH 估计方法

锂离子电池 SoH 的估计方法有多种, 目前主要可以分为测试分析法、基于模型的方法和基于数据驱动的方法三大类^[14]。近年来随着人工智能和优化算法的发展, 基于数据驱动的 SoH 估计方法得到了广泛关注^[15]。

(1) 测试分析法, 通过对电池进行一系列实验, 直接或间接获得电池的关键参数, 如电流、电压、温度等, 并通过这些参数估计电池的 SoH。该方法的优点在于直接获取电池的实时数据, 能够快速进行状态评估。常用的测试分析法包括库伦计数法、电压-容量法等。库伦计数法通过测量电池的充放电过程, 直接计算电池的放电容量, 进而估算其 SoH。NG 等人使用库伦计数法, 通过计算电池的容量衰减估计了电池的健康状态^[16]。该方法操作简单, 适用于电池的容量测试, 但在电池工作环境变化较大的情况下可能导致估计误差。此外, 基于电池内阻变化的分析也是一种常用的测试分析方法。通过测量电池的内阻结合电池的使用工况可以间接评估电池的健康状态。例如, Chu A 等人采用粒子滤波 (Particle Filter, PF) 算法结合电池内阻的变化来估计电池的 SoH^[17]。通过分析电池老化过程中的各项参数, 测试分析法能够有效提供电池健康状况的初步判断。

(2) 基于模型的方法, 通过建立电池的数学模型来描述电池的动态特性, 进而对电池的 SoH 进行估计^[18]。模型一般基于电池的电化学原理, 建立电池的电压、电流、内阻等参数与健康状态之间的关系^[19]。该方法通常先选择一个合适的模型, 并通过实验数据对模型的参数进行辨识和优化, 最后利用优化后的模型对 SoH 进行估计。卡尔曼滤波 (Kalman Filter, KF) 是广泛应用于电池 SoH 估计的经典方法^[20]。高昕等人提出了一种基于二阶 RC 电路模型和自适应遗传算法 (AGA) 的卡尔曼滤波方法用于估算电池的 SoH^[21]。此外, 扩展卡尔曼滤波 (EKF) 和无迹卡尔曼滤波 (UKF) 算法也被用于解决电池模型中的非线性问题^[22]。赵月荷等人在二阶 RC 电路模型的基础上, 使用无迹卡尔曼滤波算法估算电池的欧姆

内阻并建立内阻与 SoH 的关系^[23]。粒子滤波算法 (PF) 是另一种适用于电池 SoH 估计的非线性滤波方法。PF 基于蒙特卡洛方法, 通过随机采样和重要性加权, 能够有效估计电池的状态^[24]。徐超等人提出了一种改进的粒子滤波算法, 结合动态布谷鸟搜索优化粒子的分布, 提高了 SoH 估计的精度^[25]。此外, Bi 等人提出了一种基于电池降解过程的寿命模型并使用粒子滤波算法进行参数辨识, 实现了对 SoH 的在线估计^[26]。基于模型的方法能够较为准确地模拟电池的实际工作状态, 但由于电池在实际使用中涉及到许多复杂的物理和化学过程, 这些过程难以通过简单的模型进行完全描述, 从而限制了基于模型的方法在复杂环境中的应用。

(3) 基于数据驱动的方法通常通过获取大量的电池老化数据或状态监测数据后, 利用智能算法挖掘电池健康因子与健康状态之间的关系。近年来, 深度学习、支持向量机 (SVM)、神经网络 (NN) 等机器学习方法被广泛应用于锂电池 SoH 估计中^[27]。刘晓悦等人提出了基于粒子群算法 (PSO) 优化反向传播神经网络 (BP) 的方法并利用此方法对电池 SoH 进行了估计^[28]。李旭东等人提出了一种基于主成分分析 (PCA) 和鲸鱼优化算法 (WOA) 优化 Elman 神经网络的方法, 从而提高了 SoH 估计的精度^[29]。这些方法通过对大量电池数据的分析, 能够快速并且准确地评估电池的健康状态, 具有较高的实时性和应用价值。基于数据驱动的 SoH 估计方法能够避免对电池物理过程的复杂建模, 利用大数据和智能算法搜索电池健康因子与 SoH 之间的关系, 提高估计精度, 缩短开发时间并优化成本, 具有较高的效率和较低的开发成本^[30]。此外, 数据驱动方法的在线应用潜力巨大, 可以在电池使用过程中实时进行健康评估。

1.2.3 电池检测技术

电池检测设备是动力电池全生命周期管理的核心支撑, 其发展水平直接影响电池健康状态评估的精度与效率, 也是电池管理系统中的关键组件。通过硬件传感器和软件算法的协同作用, 实时采集和分析电池的电压、电流、温度等信息, 用于 SoH 的估算^[31]。然而, 动力电池系统的复杂性和技术壁垒导致国内外在该领域的技术路径与发展水平存在较大差异。

在国际市场上, 特斯拉、通用、宝马等汽车制造商普遍采用基于小型电芯的

模块化电池包设计,通过高度集成来实现电池的多层级管理提高效率。例如,特斯拉的 Model S 电池系统采用"电池组-电池包-单体电芯"的三级架构,电池包被划分为 16 个电池组,每个电池组包含 6 个电池包,而每个电池包又由 74 节 18650 锂电池并联而成^[32]。这种架构使得每个电池包和电池组都能配有独立的监测芯片,便于实时采集电池的电压、电流和温度数据并通过串行通信传输至主控单元进行 SoH 的估算^[33]。

在技术层面,国际领先的半导体企业已形成了完整的芯片生态链,其中,德州仪器推出的 bq67PL228Q-W2 多电池管理芯片支持多达 6 节电池的并行管理,集成过流保护、温度补偿等功能,电压检测精度可达到 $\pm 1\text{mV}$,适用于高精度 SoH 估算场景^[34]。ADI 公司开发的 AD3962 芯片则采用开路电压动态校准技术,通过充放电曲线的拐点识别,结合 SOC 和 SoH 的联合估计,降低了系统复杂度^[35]。英飞凌推出的 ASD64500 芯片采用半差分多链拓扑结构,通过双绞线传输技术有效抑制了共模干扰,在热插拔工况下仍能保持 $\pm 0.5\%$ 的电压采样精度^[36]。

在国内,我国电池产业链面对国际技术垄断和芯片受限的压力采取了与发达国家不同的技术路线。比亚迪公司发布的刀片电池采用磷酸铁锂正极材料和扁平化叠片工艺,取消了传统模组设计,将电池的体积利用率提升至 60%以上。单体电芯长度可达到 1 米,容量突破 200Ah,使得电池包内的电芯数量大幅减少,从根本上简化了电压均衡和健康监测需求^[37]。宁德时代则推出了 CTP 技术,其采用大尺寸方形电芯,单体容量较 18650 电芯提升了 15 倍,从而减少了电池包内电芯数量的 90%。这一创新大幅降低了数据采集通道的数量,降低检测系统硬件成本约 40%^[38]。

在面对芯片技术封锁的情况下,国内企业通过“软件定义硬件”的策略突破技术瓶颈。在硬件设计方面,国轩高科推出的主控芯片采用时间交织 ADC 架构,在单芯片上实现了 16 通道电压同步采样,采样速率提升至 10kS/s,满足了高倍率充放电工况下的瞬态响应需求。中创新航推出的智能模组集成了 FPGA 加速器,能够在本地完成增量容量分析的特征提取,将 SoH 估算的延迟从分钟级压缩至毫秒级,效率提升了 80%。我国还通过加强产学研协同创新,推动了电池健康状态检测技术的进步。中科院物理所提出了基于弛豫电压谱的 SoH 快速检测方法,通过分析电池静置阶段的电压恢复速率,构建了电池老化指纹数据库,并

已在蔚来汽车的电池管理系统中得到应用^[39]。同时，清华大学欧阳明高团队开发了基于超声导波的电池内部缺陷检测装置，可以实时监测电池电极膨胀和电解液干涸现象，精度达到微米级，为微观尺度的 SoH 评估提供了新的解决方案^[40]。

目前，电池检测设备的发展趋势主要集中在高精度、低延迟和低成本方面。多物理场融合检测技术正在成为研究的热点，电化学阻抗谱、热成像技术和机械应力传感的结合数据可以为电池的健康状态提供更加全面的评估。数字孪生技术也在电池健康管理中得到了应用，通过建立电池全生命周期的数字模型以实现 SoH 的虚拟标定与预测性维护^[41]。为了进一步推动电池检测技术的发展，在 2023 年工信部发布的《动力电池检测设备通用技术要求》明确了电压检测精度小于等于 $\pm 0.1\%FS$ 、温度均匀性小于等于 $\pm 1^\circ C$ 等核心技术指标，这有助于推动行业检测规范的统一^[42]。

1.3 本文研究内容

本研究围绕锂离子电池健康状态（SoH）估计及检测设备展开，重点关注基于萤火虫算法优化的门控循环单元（Gated Recurrent Unit, GRU）在 SoH 预测中的应用，并结合设计的电池测试仪进行实验验证。本文的主要研究内容如下：

第 1 章介绍了研究背景及意义，概述了锂电池 SoH 估计的研究现状，以及电池检测设备的发展趋势，明确了本研究的目标和技术路线。

第 2 章对锂电池的基本特性进行分析，首先介绍了锂电池的构造及工作原理，然后基于混合脉冲功率测试及不同倍率充放电实验，对锂电池的关键特性进行深入探讨。在此基础上分析锂电池健康状态的衰减机理，并筛选出充电过程中的恒流充电时间与恒压充电时间作为 SoH 估计模型的输入特征，同时提出一种动态特征选择策略，以缩短 SoH 完整估计时间。

第 3 章介绍了基于萤火虫算法优化门控循环单元的 SoH 估计方法。首先对输入数据进行预处理，包括奇异值分解降噪、小波变换去噪及数据归一化处理。随后对萤火虫优化算法的基本原理及其在参数优化中的应用进行描述，再对 GRU 神经网络的建模方法及结构特性进行阐述，最后展示如何利用萤火虫优化算法调整 GRU 模型超参数以提升 SoH 预测精度。基于美国马里兰大学 CALCE

电池老化数据集对模型进行测试，并与传统模型进行对比分析，验证萤火虫优化 GRU 模型的优越性及动态特征选择策略的有效性。

第 4 章设计并实现了一种 100A 双相数字控制电池测试仪。首先明确测试仪的设计目标及技术需求，然后详细介绍了硬件系统的设计，包括主控芯片、功率开关管等关键器件的选型、检测电路的构建、驱动电路与功率变换电路等的设计。此外进一步阐述了测试仪的软件架构，包括控制环路设计、数据采集及通信策略。对电池测试仪进行频率响应分析，以评估单相电流、双相电流及双相电流电压控制环路的稳定性。最后，搭建完整实验平台，结合锂电池、上位机及示波器等设备，开展 3C 充电 1.5C 放电的模拟真实工况实验，验证测试仪在实际应用场景下的性能。

第 5 章对全文研究内容进行总结，归纳所提出方法及测试系统的创新性，并展望未来的研究方向。

第2章 锂电池特性分析

锂电池因其高能量密度、长循环寿命及安全性高的优势，在现代电力设备尤其是新能源汽车领域得到了广泛应用^[43]。锂电池在长期使用过程中会出现容量衰退现象^[44]，因此了解锂电池的衰退机理并从中提取出有效的特征量进行健康状态估计具有重要意义。

2.1 锂电池基本构造与工作原理

2.1.1 锂电池基本构造

锂电池由正极、负极、电解液、隔膜和外壳五个部分构成，每一部分的材料和设计直接影响电池的性能、寿命及安全性^[45]。

正极材料是电池的核心，常见的包括磷酸铁锂、钴酸锂、锰酸锂和三元材料。负极材料一般采用导电性良好的石墨或其他碳基材料。

电解液由锂盐和有机溶剂组成，其主要作用是为锂离子的迁移提供导电介质。电解液的质量直接影响电池的效率、温度稳定性及循环寿命^[46]。

隔膜位于电池正负极之间，用于隔离正负极以防止短路，通常使用聚烯烃类材料。隔膜的孔隙率、厚度等特性直接影响电池的离子导电性和整体安全性^[47]。

外壳则为电池提供物理保护，通常采用铝或钢材质，既保证了强度，又有利于散热^[48]。

2.1.2 锂电池基本工作原理

锂电池的工作原理基于锂离子的嵌入与脱嵌过程，在此过程中完成能量的存储和释放。当电池开始放电时，电池内部的化学反应启动，正极材料中的锂离子通过电解液迁移到负极同时释放出电子。这些电子在外部电路中流动，产生电流并输出电能。与此同时，锂离子从正极脱嵌，穿越电解液和隔膜，进入负极的石墨材料中^[49]。此过程伴随着电池电压的下降，直到放电过程结束，电池的能量被

完全释放。在充电过程中，外部电源提供的电流迫使锂离子从负极的石墨材料中解嵌，穿越电解液和隔膜，迁移回正极^[50]。电源驱动电子通过外部电路从负极流向正极，与正极材料中的锂离子重新结合，完成能量的储存。随着充电的继续，更多的锂离子被吸入正极，电池电压逐渐上升，直到充电过程达到预设的终止电压，此时电池的充电过程完成，储存的电能达到最大值。






图 2-1 锂电池充放电示意图

锂电池工作时的化学反应过程如下式所示^[51]:


正极反应过程表达式:



石墨负极反应过程表达式:



电池内部总反应过程表达式:



2.2 锂电池特性实验

2.2.1 实验对象

本节实验所选用的锂电池为浙江南都生产的 64Wh 磷酸铁锂电池，标称电压

为 3.2V，额定容量为 20Ah，充电上限为 3.6V，放电下限为 2.5V。

2.2.2 实验平台

本节实验基于新威 BTS4000-5V30A 电池检测设备搭建实验平台。该设备支持最大 5V 电压和 30A 电流的测试范围，能够进行自定义充放电测试及数据采集。

实验平台如图 2-2 所示，包括 BTS4000 主机、多个电池通道以及与上位机和数据采集设备的连接，能够实现对电池进行多种实验，包括常规的容量测试、恒流恒压充放电测试、高倍率充放电实验等。




图 2-2 锂电池特性实验平台

2.2.3 混合脉冲功率特性测试实验

混合脉冲功率特性（High Power Pulse Cycling, HPPC）测试是在《Freedom CAR 功率辅助型混合电动车电池测试手册》中提出的一种用于评估锂电池在高功率脉冲充放电条件下性能的实验方法^[52]。

在本实验中，通过一系列充放电操作，获得电池在不同荷电状态（State of Charge, SoC）下的参数变化。具体实验步骤如下：

初步充电：首先将电池放电至截止电压 2.5V，然后以 20A 恒流（0.5C）充

电至 3.6V，接着进入 3.6V 恒压充电阶段，直到电流降至 1A，认为电池充满。

脉冲充放电：进行脉冲放电和充电测试，脉冲放电电流为 20A（1C），持续时间为 10 秒，充电电流为 15A（0.75C），持续时间为 10 秒，充放电之间间隔 1 分钟。每个脉冲放电和充电周期后进行 1 小时的搁置。

继续充放电：在脉冲测试完成后，进行 1C 恒流放电 6 分钟，并进行 1 小时的搁置，随后重复进行脉冲充放电测试，直到电池容量下降至 SoC 为 0.1 时停止。

建立电池 Thevenin 模型：Thevenin 模型是一种简化的电路模型，用于描述电池等能量存储装置的电气行为。在该模型中 U_{oc} 为理想电压源， R_0 为电池的欧姆内阻， R_p 为电池的极化内阻， C_p 为极化电容。




图 2-3 Thevenin 模型等效电路图

在数据分析处理过程之中，先从原始实验数据中提取出有效的数据段，进而通过分析提取出的数据段，采取合理的处理方法，获得等效电路模型的内部参数化和 SoC 之间的关系。




图 2-4 SoC=0.9 时的脉冲测试图

图 2-5 同时反应了锂电池的暂态特性和稳态特性，脉冲开始时，电池电压会快速下降，当放电结束瞬间，电压又立刻回弹，搁置期间电压有逐渐回升并趋于平稳的趋势；充电过程与放电过程的响应情况正好相反。采用取点算法对脉冲测试数据进行参数辨。

取点算法的辨识过程如下所述。首先从图中取得 A、B、C、D 和 E 共五个点。从 Thevenin 等效模型看，放电开始电压的突然下降是欧姆内阻 R_0 的作用，同样，放电结束电压的迅速回升也是 R_0 的作用，放电过程中的电压逐渐下降的现象可以用 Thevenin 模型中的 RC 电路解释。所以 AB 段和 CD 段可以得到电池欧姆内阻的值，从 BC 段和 DE 段可以得到 RC 电路的等效内阻和极化电容的值。由此可以得到参数的计算公式^[53]。其中， R_0 的计算公式为：

$$R_0 = \frac{|\Delta U_{AB}| + |\Delta U_{CD}|}{2I} \quad (2-4)$$

式中， ΔU_{AB} 为 AB 段的电压电压差； ΔU_{CD} 为 CD 段的电压差； I 为放电电流。

分析 DE 段电压对应 Thevenin 模型的零输入响应，由模型中基尔霍夫电压定律（Kirchhoff Voltage Law, KVL）关系得：

$$\begin{cases} U_D = U_A - U_{P0} e^{-\frac{0}{\tau}} \\ U_E = U_A - U_P e^{-\frac{t_E - t_D}{\tau}} \end{cases} \quad (2-5)$$

其中， U_A 表示 A 点的电压，即是当前阶段的开路电压，以 D 点为零时刻，则从 D 点到 E 点的时间为 $t_E - t_D$ ， U_D 和 U_E 分别代表 D 点和 E 点处的电压。解方程组得到时间常数 τ 的计算式为：

$$\tau = -\frac{t_E - t_D}{\ln\left(\frac{U_A - U_E}{U_A - U_D}\right)} \quad (2-6)$$

得到时间常数 τ 之后，只需计算出 R_p 或者 C_p 其中一个参数，另一个就可以由式(2-7)得出。

$$\tau = R_p C_p \quad (2-7)$$

BC 段的电压响应对应于 Thevenin 模型的零状态响应，根据模型中 KVL 关系得：

$$\begin{cases} U_C = U_A - IR_0 - IR_p \left(1 - e^{-\frac{t_C - t_B}{\tau}}\right) \\ U_B = U_A - IR_0 \end{cases} \quad (2-8)$$

其中, U_C 代表 C 点的电压, 以 B 点为零时刻, 则从 B 点到 C 点的时间为 $t_C - t_B$ 。解方程组得到极化内阻 R_P 的计算式为:

$$R_P = \frac{U_B - U_C}{I \left(1 - e^{-\frac{t_C - t_B}{\tau}} \right)} \quad (2-9)$$

根据公式计算 Thevenin 模型一阶 RC 模型参数, 得到了不同 SoC 下的模型参数。表 2-2 展示了脉冲电流为 20A, 脉冲持续时间为 10 秒时, 各 SoC 下的电池电压及 RC 模型参数。

表 2-2 不同 SOC 下 HPPC 测试结果

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_P (Ω)	C_P (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

实验记录表中可以看出, R_0 相对稳定, 在整个 SoC 范围内几乎没有明显变化, 从 SoC 为 1 到 0.5 时 R_0 保持在 0.0027Ω , 之后随 SoC 继续降低。这表明在全荷电状态范围内, 电池的欧姆内阻主要由电解质、导电材料和接触电阻等因素决定, 是一个几乎恒定的参数。

极化内阻 R_P 的变化较为复杂具有明显的非线性特征。从 SoC 为 1 到 0.1, R_P 逐渐增加, 这表明电池在充放电过程中, 随着 SoC 的降低极化效应逐渐增强。

SoC 为 1 时, R_p 的值为 0.0677Ω , 随着 SoC 的降低, R_p 值逐渐减小, 直到 SoC 为 0.5 时达到最低值 0.0170Ω 后, 再次增加至 SoC 为 0.1 时的 0.0228Ω 。这一趋势表明, 随着电池 SoC 的下降, 电池的极化现象逐步加剧, 尤其是在低 SoC 状态下, 电池内的极化效应更为明显。

极化电容 C_p 随 SoC 的下降逐渐减小, 表明电池在低 SoC 时储存和释放电荷的能力变弱。在 SoC 为 1 时, C_p 的值为 $2048.4087F$, 随着 SoC 降低为 0.1 时, C_p 的值降至 $1565.3631F$ 。 C_i 的这种减小趋势表明, 随着 SoC 的下降, 电池内部的电荷储存能力和反应活性减弱, 电池的极化电容减少, 导致电池对高频脉冲的响应能力下降。与极化内阻类似, C_p 的变化也呈现出明显的非线性特征。

SoC 与电池的 OCV 之间有着较强的线性关系, 从 SoC 为 1 到 SoC 为 0.1, 电池的 OCV 值逐渐降低, 表明随着 SoC 的降低, OCV 也在减小。




图 2-5 OCV- SoC 关系图

2.2.4 不同倍率充放电实验

本实验旨在准确测量锂电池在不同倍率充放电条件下的容量, 记录并分析电池在不同倍率放电和充电过程中的数据, 探讨倍率对电池性能的影响及其变化规律。

本实验包括不同倍率放电和不同倍率充电两部分:

不同倍率放电首先以 $10A$ ($0.5C$) 恒流将电池电量放至截至电压 $2.5V$, 清空电池; 然后以 $10A$ ($0.5C$) 恒流充电至 $3.6V$, 搁置 5 分后 $3.6V$ 恒压充电至充电电流降为 $1A$ ($0.05C$)。此时认为电池充满; 最后分别以 $2A$ ($0.1C$)、 $5A$ ($0.25C$)、

10A（0.5C）、15A（0.75C）、20A（1C）、30A（1.5C）恒流放电至截止电压 2.5V。

不同倍率充电首先以 10A（0.5C）恒流将电池电量放至截至电压 2.5V，清空电池；然后分别以 2A（0.1C）、5A（0.25C）、10A（0.5C）、15A（0.75C）、20A（1C）、30A（1.5C）恒流充电至 3.6V，搁置 5 分钟；最后以 10A（0.5C）恒流放电至截止电压 2.5V。

在实验过程中，所有电池电压、电流和时间数据将通过上位机软件实时记录，以确保实验数据的准确性和完整性。

不同倍率放电实验结果记录如表 2-3 所示，计算得到了不同倍率下的电池放电效率和容量。

表 2-3 不同倍率放电实验结果

放电倍率	充电容量/Ah	放电容量/Ah	放电效率/%
1.5C(30A)	20.5591	19.9026	96.81
1C(20A)	20.3862	19.9011	97.62
0.75C(15A)	20.3373	19.9802	98.24
0.5C(10A)	20.5132	20.1322	98.14
0.25C(5A)	20.5787	20.4194	99.23
0.1C(2A)	20.5744	20.5137	99.70




图 2-6 不同倍率放电电池电压与时间曲线

六组不同倍率放电曲线如图 2-6 所示，放电的初始瞬间，电池电压迅速下降，放电倍率越高电池电压下降越快，1.5C 时下降至 3.18V，1C 时下降至 3.22V，

倍率越高电池电压上升越快, 1.5C 时上升至 3.37V, 1C 时上升至 3.33V, 0.75C 时上升至 3.31V, 0.5C 时上升至 3.29V, 0.25C 时上升至 3.26V, 0.1C 时下降至 3.24V; 之后电池电压经过一段平缓的上升过程。如图 2-8 所示, 不同倍率充电曲线在充电容量接近总容量的 0.9 倍时, 电压再次迅速上升, 充电倍率越低上升点越靠后, 上升斜率越大。




图 2-8 不同倍率充电电池电压与容量曲线

通过对不同倍率充放电实验结果的分析, 可以得出以下几点:

1. 放电效率与放电倍率的关系。随着放电倍率的增加, 电池的放电效率呈现出下降的趋势。随着倍率的增大, 尤其是 1.5C 放电时, 放电效率降至 96.81%, 高倍率放电加剧了电池内部的能量损耗, 导致更多的能量转化为热能, 进而降低了放电效率^[54]。

2. 电池容量与放电倍率的关系。电池在低倍率放电时能够较为充分地释放其电量。随着放电倍率的增加, 由于电池电压的快速下降和内阻增大的影响^[55], 电池的实际放电容量略低于充电容量。

3. 充电过程中电压与倍率的关系。高倍率充电时, 电池电压上升速度较快, 且充电过程中电池内阻的增大可能导致充电效率的下降。电池的电压变化受到内阻影响, 在高倍率充电时表现得更加显著^[56]。

5. 极化效应对充放电效率的影响。高倍率充电过程中, 电池的极化效较为明显, 导致电池电压和电流波动较大。低倍率充放电能够使电池能量彻底交互。

2.3 锂电池健康度衰退分析及特征量选取

本研究主要基于马里兰大学高级生命周期工程中心(CALCE)提供的锂电池老化数据集,对锂电池健康度衰减过程及相关特征量进行分析,旨在通过选择与电池衰退过程关联性较高的特征量,建立有效的 SoH 估计数据驱动模型。

2.3.1 电池老化数据集介绍

本研究使用的 CALCE 电池数据集包含了四块棱柱型锂离子电池(CS2_35、CS2_36、CS2_37 和 CS2_38)的充放电循环测试数据,电池的阴极材料为 LiCoO_2 ,额定容量为 1.1Ah ^[57]。所有电池在 1°C 的环境条件下,通过 Arbin BT2000 设备进行充放电测试。测试过程中,电池以 0.5C 的恒流充电至截止电压 4.2V ,随后以 4.2V 恒压充电至电流降至 0.05A 以下;接着进行 1C 恒流放电至截止电压 2.7V 。各电池的充放电参数如表 2-5 所示。

表 2-5 电池具体参数

参数	规格
标称容量/mAh	1100
充电截止电压	4.2V
放电截止电压	2.7V
充电电流	0.5C
放电电流	1C
温度	1°C

电池的测试数据覆盖了从初始状态到容量衰减至额定容量的 30% 的全生命周期过程,定义此时为寿命终止(End of Life, EOL)^[58]。图 2-9 展示了不同电池的容量衰减曲线,电池在多次充放电循环后,容量逐渐下降,这为研究提供了基础数据支持。




图 2-9 CALCE 电池容量衰减曲线

2.3.2 容量衰减的机理分析

锂电池的容量衰减通常是由于多种因素的共同作用，主要涉及以下几个方面：

1. 电池内阻的增大

随着电池充放电循环次数的增加，电池内部的欧姆内阻和极化内阻逐渐增大，电池的内阻增大直接导致其放电效率下降和容量衰减。内阻增大使得电池在充放电过程中产生更多的热量，不仅降低了充放电效率还加速了电池的老化^[59]。

2. 极化效应的增强

锂电池在充放电过程中，随着电池容量的逐渐衰减，极化效愈加明显。极化效应主要是指在充电和放电过程中，电池内部发生的电荷分离现象，导致电压与电流之间出现较大差异。随着电池使用时间的增加，电池的极化程度逐渐增加，导致电池在恒流充电阶段的时间逐渐缩短，同时在恒压充电阶段的时间逐渐延长。

3. 电极材料的退化与副反应的发生

锂电池的容量衰减还与电池内部电极材料的退化密切相关。特别是在高倍率充放电的条件下，电池内部的锂离子嵌入和脱嵌过程不完全，导致电极材料的部分损伤和副反应的发生，进而加速了容量的衰减。

4. SEI 膜的增厚与电解液的分解

锂电池中的固体电解质界面（SEI）膜在循环过程中会逐渐增厚，在长时间高倍率充放电的情况下最为明显。SEI 膜的增厚不仅增加了电池的内阻，还可能

阻碍锂离子的流动，从而影响电池的性能。

2.3.3 特征量分析与选取

在锂电池健康度估算中，电池的容量衰减是最直接的指标。然而电池的容量衰减通常无法直接测量，需要通过可获取的电池充放电参数进行间接估算^[60,61]。

如图 2-10 所示，展示了电池的容量、内阻、恒流充电时间、恒压充电时间与循环次数的关系。




图 2-10 各项指标与循环周期

电池的容量衰减最直接的特征就是内阻的增大，尤其是在高倍率充放电时，内阻效应更加明显，导致电池的放电容量下降。但内阻的波动常受到电池工作条件、温度、充放电速度等多个因素的影响，从而增加了对内阻作为单一特征进行 SoH 估计的难度。另外在实际应用中，电池内阻的测量需要较为复杂的电气模型和测量设备，通常需要对电池进行额外的测试和校准。相比之下，恒流充电时间和恒压充电时间作为充电过程中的时间特征，相对更加稳定，能够提供一个较为一致的反映电池健康状态的依据，并且仅需要通过电池充电过程中的电流和电压变化即可获得，数据提取较为简便。

恒流充电时间（Constant Current Charging Time, CCCT）是指在充电过程中，

电池电压逐渐上升而电流保持恒定的阶段^[62]。该阶段的持续时间直接反映了电池的可用容量,随着电池老化,电池内部的化学反应发生变化导致极化效应增强,进而影响充电过程。具体来说,随着电池健康状况的衰退,内部电阻的增加使得恒流充电时间逐渐缩短。随着充电循环次数的增加,CCCT 逐渐减小^[63]。所以恒流充电时间作为特征量可以有效反映电池衰退过程中的容量损失。

恒压充电时间 (Constant Voltage Charging Time, CVCT) 是指在恒压充电阶段,电池的电压保持在设定值,电流逐渐减小的过程。随着电池老化,内阻的增加使得电池的极化效应加剧,从而导致恒压充电时间的延长^[64]。因此, CVCT 的变化能够反映电池的极化状态及老化程度。随着充电循环次数的变化,表明随着电池老化, CVCT 呈现出逐步增大的趋势,这与电池的健康状态呈现反向关系。

为了定量分析 CCCT 和 CVCT 与电池 SoH 之间的相关性,本研究使用 Spearman 秩相关系数进行分析。该系数可有效评估两组数据之间的关联程度,若相关系数绝对值为 0.8~1,则认为变量之间具有强相关性。具体公式如下^[65]:

$$r(X,Y) = 1 - \frac{6 \sum_{j=1}^n d_j^2}{n(n^2 - 1)} \quad (2)$$

其中, $(x_1, x_2, \dots, x_n)$ 、 $(y_1, y_2, \dots, y_n)$ 分别为来自总体 X、Y 的样本, $R(x_j)$ 、 $R(y_j)$ 分别表示在样本 $(x_1, x_2, \dots, x_n)$ 、 $(y_1, y_2, \dots, y_n)$ 中的秩, $d_j = R(x_j) - R(y_j)$ 为两组数据中每一项的秩差, $j=1,2,\dots,n$ 。

表 2-6 展示了 Spearman 秩相关系数计算的结果,表明 CCCT 和 CVCT 与电池 SoH 之间均具有较强的相关性。

表 2-6 特征参数与 SoH 的 Spearman 相关系数计算结果

特征指标	CCCT	CVCT
Spearman 相关系数	CS2_35	0.9729
	CS2_36	-0.8753
	CS2_37	0.9596
	CS2_38	-0.7592
		-0.8915
		-0.8653

在不同初始容量和充电状态下,电池的恒流充电 (CC) 和恒压充电 (CV) 阶段表现出不同。对于恒流充电时间较长的电池,恒流充电时间 (CCCT) 作为

单一特征与 SoH 具有较强的相关性。这表明在电池深度放电或低容量状态下，恒流充电阶段的时间特征能够高度浓缩电池内部劣化的关键信息。因此，CCCT 可以作为可靠的健康状态指标。

当恒流充电时间较短时，引入恒压充电时间（CVCT）作为补充特征可以进一步提高预测的全面性。恒压充电阶段的时间特征能够捕捉到恒流充电阶段未能完全体现的电池微观状态变化，例如电池内部的充电饱和度和界面钝化程度等。因此，CVCT 对于电池老化过程中的特征补充具有重要作用。

最理想的情况是在从零电量开始的完整充电过程中，CCCT 和 CVCT 共同作用，此时能够提供最佳的 SoH 预测。这一策略利用了两个时间特征在整个充电周期中的互补性，并能够全面描绘电池在不同充电阶段的健康演变过程。

2.4 本章小结

本章首先介绍锂电池的结构与工作原理，分析其在充放电过程中涉及的主要电化学反应及内部运行机制；接着展示了用于研究锂电池特性的实验方法，并对实验数据进行整理和分析；最后对锂电池的衰退机理进行探讨，选择合适的特征量，为后续的 SoH 估计方法奠定基础。

第3章 基于萤火虫算法优化 GRU 模型的 SoH 估计方法

对于锂电池充放电过程中采集到的恒流充电时间、恒压充电时间数据，采用基于萤火虫算法优化的门控循环单元神经网络模型，用于锂电池 SoH 的估计。

3.1 数据预处理

数据预处理是机器学习任务中的关键步骤之一，在锂电池健康状态预测中，数据质量对模型的准确性具有直接影响。本节详细介绍了用于本研究中的数据预处理过程，包括奇异值定阶降噪、小波变换降噪以及归一化处理。这些方法能有效地去除噪声、提高数据质量，为后续的模型训练提供更为可靠的数据基础。

(1) 奇异值定阶降噪

奇异值分解（Singular Value Decomposition, SVD）是一种常用的矩阵分解技术，在降噪和信号处理领域得到了广泛应用^[66]。SVD 通过将原始矩阵分解为三个矩阵的乘积，从而揭示数据中最重要的特征。具体而言，任何矩阵 A 都可以表示为^[67]：

$$A = U\Sigma V^T \quad (3-1)$$

其中： A 是大小为 $(m \times n)$ 的原始矩阵； U 为 $(m \times r)$ 的正交矩阵，包含了矩阵 A 的左奇异向量； V 是 $(n \times r)$ 的正交矩阵，包含了矩阵 A 的右奇异向量； Σ 为 $(r \times r)$ 的对角矩阵，其对角线上的元素称为奇异值按降序排列，且都非负， r 为矩阵 A 的秩数。

$$\Sigma = \begin{bmatrix} \sigma_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sigma_r \end{bmatrix} = \begin{bmatrix} \sqrt{\lambda_1} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sqrt{\lambda_r} \end{bmatrix} \quad (3-2)$$

$$\Sigma = \begin{bmatrix} \sigma_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sigma_r \end{bmatrix} = \begin{bmatrix} \sqrt{\lambda_1} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sqrt{\lambda_r} \end{bmatrix}$$

奇异值的大小反映了原始矩阵中特征向量的重要性,较大的奇异值对应着较为显著的信息。通过选择较大的奇异值并重构原始矩阵,可以有效实现数据降噪。

在本研究中,采用 SVD 方法对原始数据进行降噪处理,保留了最重要的奇异值,消除了噪声成分。经过降噪处理后,计算得到的 Spearman 相关系数结果如表 3-1 所示,所有特征的相关性系数均超过 0.8,且降噪后各特征的相关性系数均有所提高,表明降噪处理有效提升了数据质量。

表 3-1 降噪后的的 Spearman 相关系数

特征指标	CCCT	CVCT
Spearman 相关系数	CS2_35	0.9790
	CS2_36	-0.8862
	CS2_37	0.9642
	CS2_38	-0.8102
		-0.8997
		-0.8710

(2) 小波变换降噪

小波变换 (Wavelet Transform, WT) 是一种能够对信号进行多尺度分析的强大工具,广泛应用于信号处理和噪声抑制。在电池数据处理中,小波变换能够将信号分解为不同的频率和时间尺度,从而在不同尺度上对信号进行有效降噪^[68]。连续小波变换的核心公式为:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (3-3)$$

其中, $\psi(t)$ 为母小波函数,用于描述信号的局部特征; a 为尺度因子,表示小波的伸缩,影响信号的频率分布, $a > 0$; b 为平移因子,表示小波函数的平移, $b \in \mathbf{R}$; $\frac{1}{\sqrt{a}}$ 为归一化因子,确保小波变换的能量不随尺度变化而变化。通过对信号平移和缩放操作构造出不同尺度和位置的小波基,可以将其分解为多个层次的系数,这些系数代表了信号在不同时间和频率上的特征。

本研究对原始信号进行小波变换,设定合适的阈值处理小波系数,将小于阈值的系数置零并按照一定规则进行收缩。然后利用处理后的小波系数对信号进行重构,从而有效减少噪声对数据的干扰,提升信号的质量。

(3) 归一化

归一化是机器学习中常用的数据预处理技术,尤其对于特征量纲和量级差异

较大的数据，归一化有助于消除这些差异对模型训练的影响。采用最小-最大归一化方法，将数据按如下公式映射到[0, 1]区间：

$$y' = \frac{y - \min(y)}{\max(y) - \min(y)} \quad (3-4)$$

其中， y 为原始数据， $\max(y)$ 和 $\min(y)$ 分别为特征的最大值和最小值。归一化不仅加速了优化算法的收敛速度，还能提高神经网络模型的拟合精度和稳定性。

3.2 萤火虫优化算法

萤火虫优化算法（Firefly Algorithm, FA）是一种新型的仿生智能优化算法，由 Yang Xinshe 于 2009 年提出，该算法的灵感来源于自然界中萤火虫群体的发光行为和相互吸引现象^[69]。在萤火虫算法中，每个萤火虫代表一个解，其亮度与目标函数值直接相关，亮度越高，表示解的质量越好。萤火虫个体通过彼此之间的亮度差异相互吸引，亮度较低的个体会朝着亮度较高的个体移动。通过不断迭代更新个体位置，整个群体在多个搜索步骤中趋近于最优解，从而实现全局最优解的搜索。

萤火虫的亮度表示了个体解的优劣，亮度越高，解的质量越好；吸引力则决定了其他萤火虫向其移动的程度，吸引力越大，移动的距离越长。吸引力的大小与距离和亮度成正比，这一过程通过公式进行描述：

$$I(r) = \frac{I_s}{r^2} \quad (3-5)$$

在此公式中， $I(r)$ 表示光强度； I_s 是最亮个体的光强度； r 为萤火虫之间的距离。为了避免距离为零的情况，可以用高斯函数来近似光强度与距离的关系：

$$I(r) = I_0 e^{-\gamma r^2} \quad (3-6)$$

其中， γ 为吸引力衰减系数，通常 $r \in [0.01, 100]$ ； I_0 是最亮个体的亮度。该公式表明，萤火虫之间的吸引力随着距离的增大而快速衰减。

在萤火虫算法中，吸引力的强度与亮度直接相关。萤火虫之间的吸引力可以表示为：

$$\beta(r) = \beta_0 e^{-\gamma r^m} \quad (3-7)$$

其中， β_0 为距离为零时的最大吸引力，一般取 $\beta_0 = 1$ ； m 为问题的局部最优

值的影响因子。

两个萤火虫之间的距离 r_{ij} 可以通过欧几里得距离来计算：

$$r_{ij} = \sqrt{\sum_{k=1}^D (x_{ik} - x_{jk})^2} \quad (3-8)$$

其中， x_{ik} 和 x_{jk} 分别表示第 i 个和第 j 个萤火虫在第 k 维的坐标； D 为解空间的维度。

在每次迭代中，萤火虫 i 会根据吸引力向较亮的萤火虫 j 的位置移动。位置更新的公式如下：

$$x_i(t+1) = x_i(t) + \beta(r_{ij})(x_i - x_j) + \alpha\varepsilon_j \quad (3-9)$$

其中， $x_i(t)$ 和 $x_j(t)$ 分别表示第 i 个和第 j 个萤火虫在第 t 次迭代时的位置； $\beta(r_{ij})$ 表示吸引力； α 是随机步长，用于引入扰动， $\alpha \in [0,1]$ ； ε_j 是服从高斯分布的随机数。扰动 $\alpha\varepsilon_j$ 是萤火虫算法的一个关键策略，通过引入扰动，增强了个体的多样性，避免萤火虫陷入局部最优解。

萤火虫算法的优势在于其操作简单、参数较少且只需调整吸引力的衰减系数和最大吸引度。其群体间信息共享能力强、鲁棒性好，能够在缺乏先验知识的情况下进行有效的迭代搜索。此外，萤火虫算法具有较强的自适应能力，能够根据不同问题的需求进行调整，适应多种优化情境。但也存在一定的局限性，例如在接近最优解时，可能会出现算法振荡的问题，导致收敛速度较慢。因此，在实际应用中需要合理地调整参数，平衡探索和开发，以提高收敛速度和优化效果。

3.3 GRU 门控循环单元网络

门控循环单元网络（Gated Recurrent Unit, GRU）是一种改进的循环神经网络（RNN），被广泛应用于处理时序数据和序列预测任务^[70]。与传统的 RNN 相比，GRU 通过改进其结构和机制，显著提升了在长时间依赖问题上的表现，同时也在计算效率上进行了优化。GRU 的设计灵感来自于长短时记忆网络（LSTM），

但它通过简化结构，减少了参数数量，并降低了计算复杂度，使得 GRU 在许多任务中比 LSTM 更加高效。

如图 3-1 所示，GRU 将输入门和遗忘门合并为一个更新门，并去除了单独的单元状态。更新门用于调节当前输入与历史状态对新状态的影响程度，决定了模型是保留历史信息还是接受新的信息；而重置门则控制历史信息对当前计算的贡献，重置门的值越高，保留的历史信息就越多。




图 3-1 GRU 结构图

具体来说，GRU 通过以下关键方程来更新隐藏状态：

1.更新门的状态：

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (3-10)$$

2.重置门的状态：

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (3-11)$$

3. 候选隐藏状态的计算：

$$\tilde{h}_t = \tanh(W_h \cdot [z_t * h_{t-1}, x_t] + b_h) \quad (3-12)$$

4.最终隐藏状态的更新：

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (3-13)$$

在上述公式中： z_t 和 r_t 分别表示更新门和重置门的状态； $\tilde{h}_t$ 是当前时间步的候选隐藏状态； h_t 是最终的隐藏状态，是模型的输出； σ 为 sigmoid 激活函数，数学表示为 $\sigma(x) = 1/(1 + e^{-x})$ ，可将任何实值输入映射到 0 到 1 之间的值，在重置和更新门控中起着计算和概率解释作用； $\tanh$ 为双曲正切激活函数定义为 $\tanh(x) = (e^x - e^{-x})/(e^x + e^{-x})$ ，将输入值映射到-1 到 1 之间的范围，主要用

于使用非线性变换计算候选隐藏状态； W_z 、 W_r 、 W_h 是权重矩阵， b_z 、 b_r 、 b_h 是偏差项。

在 GRU 网络中，时间 t 表示序列中的当前时间步，网络在该时间步处理输入数据和状态转移。输入变量 x_t 来自于时间序列的当前值或已处理的特征，它是神经网络学习和处理的基础信息。而 h_{t-1} 是前一个时间步的隐藏状态，它携带着前一个时刻的上下文信息，确保网络能够理解并利用历史数据进行预测。

GRU 的关键在于重置门 r_t 和更新门 z_t 的交互作用。通过这种机制，GRU 能够高效地保留历史信息并整合当前输入，从而实现对序列数据的有效建模。

GRU 网络结构特别擅长处理长时间序列数据，尤其是当输入特征呈现时序性时。在本研究中，所选的特征如恒流充电时间(CCCT)和恒压充电时间(CVCT)均为一维的时间序列数据，作为 GRU 神经网络的输入。通过复杂的非线性映射，GRU 网络能够预测电池的健康状态 (SoH)。在数学上，电池的健康状态可以表示为输入特征的函数关系：

$$SoH = f(F1, F2) \quad (3-14)$$

其中， $F1$ 和 $F2$ 分别代表恒流充电时间 (CCCT) 和恒压充电时间 (CVCT)。这些特征输入到 GRU 网络参与训练，模型能够根据历史充电数据和输入特征进行预测，进一步提高 SoH 估计的准确性和可靠性。

3.4 萤火虫算法优化 GRU 神经网络

为了提高锂电池健康状态 (SoH) 预测的精确度，本研究采用了萤火虫优化算法 (FA) 来对 GRU 神经网络的超参数进行精细调优。电池的 SoH 预测任务依赖于对电池健康数据的精确建模，GRU 网络由于其对时序数据的优秀处理能力，故本研究选用其作为基础模型。然而，GRU 模型的性能高度依赖于超参数的设置，这些超参数包括学习率、迭代轮次和神经元数量等。萤火虫算法的初始参数设置涵盖了种群规模、最大迭代次数以及优化维度等。在优化过程中，萤火虫算法根据输入特征的不同，动态调整 GRU 模型的超参数，例如学习率、隐藏层维度和 GRU 层数。通过对这些超参数的优化，有效提升模型在电池健康度预测任务中的精度和泛化能力。萤火虫算法优化 GRU 神经网络模型的应用流程如图

3-2 所示。




图 3-2 萤火虫算法优化的 GRU 神经网络流程图

(1) 数据预处理与特征提取

在数据预处理阶段，首先从电池老化数据中提取两个关键特征：恒流充电时间（CCCT）和恒压充电时间（CVCT）。这些特征对于描述电池的健康状态（SoH）具有重要意义。针对数据中的缺失值，采用列均值填充的方法进行处理，以确保数据的完整性。随后，通过奇异值分解（SVD）和小波变换（WT）进行降噪，并对数据进行标准化处理，便于后续模型训练。

在特征提取和选择过程中，根据电池的充电时间长短动态调整输入特征和预测策略。当电池的恒流充电时间较长时，选择 CCCT 作为主要输入特征。恒流充电阶段的时间直接反映了电池在低容量或深度放电状态下的行为，且与 SoH 具有较强的相关性。长时间的恒流充电意味着电池的极化效应较小，电池内部的化学反应较为稳定，故此时的 CCCT 能够充分反映电池的健康状况。

相反，当恒流充电时间较短时，恒压充电阶段对电池的状态变化更为敏感，因此引入 CVCT 作为输入特征。恒压充电阶段主要影响电池的极化程度和充电饱和度，能够捕捉到电池在充电过程中未能完全体现的微观变化，例如电池内部的界面钝化和电解液成分的变化。通过引入 CVCT，模型能够更全面地识别和捕

捉电池在不同充电阶段的微观状态变化，进一步提升预测的精度。

理想情况下，从零电量开始的完整充电过程能够使得 CCCT 和 CVCT 共同作用，提供最全面的电池健康状态信息。这两项特征在充电周期中互为补充，有效结合后能够全面刻画电池健康度的演变过程，从而提高 SoH 预测模型的预测精度。

（2）萤火虫算法优化

萤火虫算法的优化重点是通过调节 GRU 神经网络的超参数来提高其预测准确性。目标函数结合了均方根误差（RMSE）、平均绝对误差（MAE）和相关系数（ R^2 ），以全面评估模型在电池健康状态预测方面的表现。待优化的超参数包括学习率、GRU 隐藏层节点数和 GRU 层数，这些参数构成了优化搜索空间，萤火虫算法在此空间中进行搜索以找到最小化误差并提高预测准确性的最佳超参数配置。

在优化过程中，首先初始化萤火虫群体，每个萤火虫代表一个超参数组合，位置即为一组超参数的值。萤火虫算法通过随机生成多个萤火虫，每个萤火虫的位置代表学习率、GRU 隐藏层维度和 GRU 层数等超参数的初始值。根据目标函数计算每个组合的适应度。萤火虫的适应度计算公式如下：

$$Objective\ Score = RMSE + 0.5 \times MAE + 0.3 \times (100 - R^2) \quad (3-15)$$

萤火虫根据适应度值相互吸引，适应度较好的火虫能够“吸引”其他萤火虫。萤火虫根据其适应度和吸引力的计算公式不断移动，以寻找到最优解。更新火虫位置的公式如下：

$$x_i = x_i + \alpha \cdot (\beta \cdot (x_{best} - x_i) + \gamma \cdot noise) \quad (3-16)$$

其中： α 是步长，控制萤火虫移动的速度； β 是吸引系数，决定萤火虫之间的相互吸引力； γ 是噪声强度，用于增加随机性； x_i 是当前萤火虫的位置； x_{best} 是最佳萤火虫的位置，即当前最优超参数组合。

通过多次迭代，萤火虫群体不断调整位置，逐渐收敛到最优解。每一代迭代后，更新所有萤火虫的位置，并根据目标函数重新计算适应度，直到达到预设的最大迭代次数。通过这种迭代过程，萤火虫算法能够在高维度的搜索空间中高效地找到最优参数组合，为后续的网络训练提供参数支持。

（3）网络模型建立及训练

当萤火虫算法优化过程结束并输出最优超参数后便可建立最终的 GRU 神经网络模型。输入层的维度由预处理后的特征数据决定，网络采用多层 GRU 结构以提取电池健康状态的时序特征。GRU 层数和隐藏层维度是重点优化的超参数，默认使用 ReLU 激活函数。输出层为全连接层，用于输出预测的电池 SoH。

在训练过程中，采用均方误差（MSE）作为损失函数，使用 Adam 优化器进行优化，并结合学习率调度器动态调整学习率。通过批量训练方法对电池数据进行逐步训练，不断更新网络权重，直至模型损失最小化。每一轮训练结束后，评估模型的性能，并更新最优的 GRU 模型，确保最终的 SoH 预测具有较高的准确度。

3.5 结果分析

3.5.1 SoH 估计实验配置

本研究实验数据来源于 CALCE 的 CS2-35、CS2-36、CS2-37 和 CS2-38 老化数据。为了进行有效的健康状态预测，本实验通过萤火虫算法的循环和交叉验证的方式动态划分，交替使用每个电池作为测试集，将剩下三块电池数据作为训练集。为体现本研究所提模型的优越性，分别对比了 LSTM 模型、GRU 模型、SVD-GRU 模型和基于 SVD-FA-GRU 模型的预测性能，最终验证了优化后模型在电池健康状态预测中的有效性和准确性。考虑到实际应用场景中电池当前荷电状态未知，提出了一种动态调整输入特征的检测思路，对双特征与单独特征估计进行了讨论。

使用均方根误差（RMSE）、平均绝对误差（MAE）、平均绝对百分比误差（MAPE）和决定系数（ R^2 ）作为评价指标，对模型的性能进行全面评估。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3-17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3-18)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3-19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3-20)$$

式中：

y_i ——第*i*个样本的真实值；

$\hat{y}_i$ ——第*i*个样本的预测值；

$\bar{y}$ ——第*i*个样本的预测值；

i ——样本个数。

3.5.2 SoH 估计方法验证

(1) 双特征输入

针对四组电池数据，使用 F1（恒流充电时间 CCCT）和 F2（恒压充电时间 CVCT）作为输入特征，四种模型对其 SoH 的预测效果如图 3-3~图 3-6 所示。表 5-1 展示了经过萤火虫算法优化后的 GRU 神经网络模型与其他 3 种网络模型的精度，在所有预测样本中，RMSE、MAE、MAPE、 R^2 都表现得更优。




图 3-3 CS2_35 预测结果对比图




图 3-4 CS2_36 预测结果对比图




图 3-5 CS2_37 预测结果对比图




图 3-6 CS2_38 预测结果对比图

由表 3-2 可看出, SVD-FA-GRU 模型的估计效果与真实数据更加贴合, RMSE、MAE、MAPE、 R^2 均为 4 个模型中最小。以 CS2_37 电池, LSTM、GRU、SVD-GRU、SVD-FA-GRU 模型的 RMSE 分别为 0.0556、0.0603、0.0553 和 0.0324, SVD-FA-GRU 相较于 SVD-GRU, RMSE 误差值减少了 0.0229, 减少了 41.40% 的误差值, SVD-FA-GRU 模型的 R^2 相较于 SVD-GRU 模型提高了 0.0466, 预测结果相关性提高了 5.01%。对于 CS2_38 电池, SVD-FA-GRU 模型预测效果改善最为明显, RMSE 和 R^2 分别达到了 0.0215 和 0.9889, 较于 SVD-GRU 模型改善了 59.28%和 5.99%。综上所述, SVD-FA-GRU 相比于其他三个模型, 在鲁棒性和准确性上均有不同程度提升, 这证明了 SVD-FA-GRU 模型在 SoH 预测中的性能。

表 3-2 预测性能对比

电池	模型	RMSE	MAE	MAPE	R^2
CS2_35	LSTM	0.0484	0.0282	4.31%	0.9459
	GRU	0.0447	0.0232	3.74%	0.9538
	SVD GRU	0.0442	0.0204	3.56%	0.9549
	SVD FA GRU	0.0344	0.0137	2.11%	0.9727
CS2_36	LSTM	0.0608	0.0287	6.25%	0.9450
	GRU	0.0606	0.0229	4.09%	0.9453
	SVD GRU	0.0596	0.0247	5.40%	0.9471
	SVD FA GRU	0.0542	0.0174	3.60%	0.9563
CS2_37	LSTM	0.0556	0.0270	4.11%	0.9285
	GRU	0.0603	0.0282	4.31%	0.9159
	SVD GRU	0.0553	0.0258	4.56%	0.9291
	SVD FA GRU	0.0324	0.0145	2.34%	0.9757
CS2_38	LSTM	0.0549	0.0238	3.52%	0.9276
	GRU	0.0544	0.0242	3.24%	0.9289
	SVD GRU	0.0528	0.0263	4.22%	0.9330
	SVD FA GRU	0.0215	0.0145	2.09%	0.9889

(2) 单特征输入

在模型训练过程中，选取不同的特征会有不同的实际意义。对于 SVD-FA-GRU 神经网络模型的特征为 F1(恒流充电时间 CCCT)、F2(恒压充电时间 CVCT) 的不同情况进行了讨论。

在待检测锂电池当前荷电容量较低的场景中，仅输入 F1（恒流充电时间 CCCT），以 CS2_35、CS2_36、CS2_37、CS2_38 为例，预测结果如图 3-7 所示：




图 3-7 CCCT 特征的电池 SoH 预测对比图

表 3-3 CCCT 特征预测的评价指标

电池	RMSE	MAE	MAPE	R ²
CS2_35	0.0355	0.0141	2.13%	0.9709
CS2_36	0.0570	0.0194	4.08%	0.9517
CS2_37	0.0481	0.0167	2.98%	0.9464
CS2_38	0.0313	0.0182	2.58%	0.9765

预测性能方面，如表 3-3 所示，四块锂电池 RMSE 分别为 0.0355、0.0570、0.0481、0.0313，相较于同时输入 F1 和 F2 特征略有增加，分别增加了 0.0011、

0.0028、0.0157、0.0098， R^2 分别下降了 0.18%、0.48%、3%、1.25%，这表明仅使用 CCCT 特征的预测精度略低于双特征输入方案且降幅相对可控。更重要的是，这种单特征预测方法在实际电池检测中具有显著工程价值。由于恒流充电阶段仅占完整充电过程 75%左右，基于 CCCT 的预测策略可简化检测流程，无需收集完整充电数据，直接基于恒流充电阶段评估 SoH。这种方法不仅保持较高准确性，还为电池健康状态快速评估提供了一种经济高效的技术路径。

在待测锂电池当前荷电容量较高的场景中，仅输入 F2(恒压充电时间 CVCT)，占完整充电时长的 25%左右，以 CALCE 高级生命周期工程中心的电池循环测试数据集 CS2_35、CS2_36、CS2_37、CS2_38 为例，预测结果如图 3-8 所示：




图 3-8 CVCT 特征的电池 SoH 预测对比图

预测性能方面，如表 3-4 所示，四块锂电池 RMSE 分别为 0.1092、0.1700、0.1032、0.1063， R^2 分别为 0.7247、0.7696、0.7533、0.7288。图中可以看出在循环次数为 100 次~400 次、SoH 在 75%~90%的区间内，与真实值的匹配度较高。对于符合相应条件的锂电池若只收集恒压充电阶段数据，可以获得较好预测精度的同时，省去了大部分恒流充电时间，不失为一种效率极高的检测方法。

表 3-4 CVCT 特征预测的评价指标

电池	RMSE	MAE	MAPE	R ²
CS2_35	0.1092	0.0692	12.38%	0.7247
CS2_36	0.1700	0.0987	16.77%	0.7696
CS2_37	0.1032	0.0567	11.16%	0.7533
CS2_38	0.1063	0.0704	10.99%	0.7288

3.6 本章小结

本章提出了一种基于萤火虫优化的门控循环单元（GRU）神经网络模型用于估计锂电池的健康状态（SoH）。首先对电池老化数据进行降噪处理，通过采用奇异值分解（SVD）和小波变换（WT）方法减少噪声影响，并对数据进行标准化处理。接着介绍了萤火虫优化算法（FA），阐述其原理、功能及其在优化神经网络超参数中的优势。然后详细讲解了 GRU 门控循环单元网络的基本结构与功能并说明如何利用 GRU 网络捕捉电池数据中的长时依赖特征。最后结合前述特征，使用差异化提取方法，通过萤火虫优化算法对 GRU 模型超参数多次迭代优化和动态调整网络参数，进一步提高电池健康状态预测的准确性。利用 CALCE 电池数据集验证了萤火虫算法优化 GRU 模型的精确性及差异化特征选取策略的有效性。

第4章 电池测试仪设计

4.1 测试仪设计目标与需求

电池测试仪是一种用于测试单个电芯、电池模块以及高压电池包的专用设备。测试设备需要集成精密电源和数据采集系统，能够为电池提供充电和放电功能并测量电芯在工作过程中的各项电气参数。

电池测试仪旨在提供高精度、高效率的电池充放电测试功能，能够满足多样化的测试需求。其设计目标主要包括以下几个方面：

1.测试仪支持正向和反向电流的双相充放电，能够适应不同类型电池的测试需求。双向充放电能力可以模拟真实工况下的充放电场景，进一步提升结果的可靠性和实用性。

2.测试仪能够实现对电池电压、电流的精确测量，能够精确捕捉电池在充放电过程中的微小变化，以确保测试数据的高可靠性和高准确性。

3.测试仪可通过数字控制系统实现对充放电过程的精确调节。其可编程功能使得用户能够根据不同电池的特性和测试需求，灵活配置充放电策略。支持包括恒流充电、恒压充电、阶梯充放电等多种充放电方式，且能够根据电池在测试中的表现动态调整策略，使得测试仪能够适应不同电池的充放电特性，同时提供灵活的测试配置，满足多样化的实验需求，以更好地模拟电池在实际使用中的工作状态。

4.为了保障测试过程的安全性，电池测试仪需具备多重保护机制，包括过压、过流、过温等保护功能。在测试过程中实时监控电池状态，防止电池因异常情况而发生故障或安全事故。

4.2 硬件架构设计

本研究设计了一款 100A 双相数字控制电池测试仪，主要包括主控单元、功率转换单元、测量单元和保护电路四个模块，图 4-1 展示了电池测试仪的参考设计方框图。电池测试仪的工作原理基于主控芯片对电压和电流的精确调控。系统

通过主控芯片生成脉宽调制（PWM）信号，PWM 信号驱动开关管（MOSFET）工作，从而调节电池充放电过程中输出的电压和电流。PWM 信号的占空比直接影响开关管的导通时间和截止时间，进而控制电流的流动和电压的输出。

在此过程中，电池端的电压通过传感器被实时监测并反馈到主控芯片。主控芯片根据电池电压信息和预设的工作参数，实时调整 PWM 信号的占空比，从而实现电池充放电电流的精确控制。这一控制机制利用负反馈原理，确保系统的稳定性和电池测试过程中的准确性。




图 4-1 测试仪系统框图

表 4-1 关键系统参数规格

参数	规格
电池端口输出电压	50mV-6V
总线输入电压	12V-15V
最大输出电流	±100A
每相最大输出电流	±50A
开关频率	100kHz
电流调节误差	< ±20mA (0.02% FS)
电压调节误差	< ±1mV (0.02% FS)

通过不断调整 PWM 信号的占空比,系统能够在不同的工作状态下保持电池电压和电流在目标范围内,确保电池测试的精确度及测试过程的安全性。此外,负反馈机制能够有效消除由于外部干扰或系统参数变化引起的误差,使得电池测试仪在整个测试过程中能够稳定、高效地工作。

4.2.1 主控芯片功能与选择

本设计采用了 TMS320F280039 微控制单元作为核心控制单元。TMS320F280039 属于德州仪器 (Texas Instruments, TI) C2000 系列微控制器,采用高性能的 32 位处理器架构,具有强大的实时控制能力。

TMS320F280039 还能够生成高分辨率的 16 位脉宽调制 (PWM) 信号。通过调节 PWM 信号的占空比,可以对电流和电压的精确调节。通过内部集成的高精度模数转换器 (ADC) 和数字信号处理器 (DSP),该微控制单元可以实时监测电池电压和电流等关键参数,并进行快速反馈调整。它还具备多个模拟输入和输出接口,能够支持外部电压、电流和温度传感器的精确测量。这些接口通过集成的 12 位 ADC 模块进行信号采集,为电池测试仪提供了高精度的电池参数监测能力。

4.2.2 关键器件选型

在设计的 100A 双相数字电池测试仪中,选用了多种高性能关键器件来实现精确的电池充放电控制、信号采集和数据转换。

开关元件选用了德州仪器的 CSD17556Q5B 型号 SiCMOSFET。基于碳化硅 (SiC) 材料的功率半导体器件具备出色的电气性能和热性能,适用于高功率和高频率应用^[71]。该器件的导通电阻较低,具有更高的耐压能力以及更低的开关损耗。CSD17556Q5B 可以支持最大 100A 的输出电流,确保了测试仪在最大输出电流的工作条件下稳定运行,并在电池充放电过程中保持高效的电能转换效率。

表 4-2 功率器件主要参数表

参数	符号	测试条件	典型值
击穿电压	$V_{(BR)DSS}$	$V_{GS}=0V$, $I_{DS}=250\mu A$	30V
通态电阻	$R_{DS(on)}$	$V_{GS}=4.5V$, $T_J=25^\circ C$, $I_{DS}=40A$	1.5m Ω
门级阈值电压	$V_{GS(TH)}$	$V_{GS}=V_{DS}$, $I_D=250\mu A$	1.4V
门极电荷量	Q_G	$V_{DS}=15V$, $I_{DS}=40A$	3.0nC
输入电容	C_{iss}	$V_{GS}=0V$, $V_{DS}=15V$, $f=1MHz$	5400pF
开通延迟	$t_{d(on)}$		14ns
上升时间	t_r	$V_{GS}=4.5V$, $V_{DS}=15V$,	26ns
关断延迟	$t_{d(off)}$	$I_{DS}=40A$, $R_G=2\Omega$	27ns
下降时间	t_f		12ns

选用了 Powerhen 的 PD3540-682KE 大功率电感，主要应用于同步升降压电路中发挥续流作用。该电感具备 75A 的额定饱和电流和最大 1.2m Ω 的直流电阻，能够在电池充放电过程中实现平稳的电流传输和滤波功能。在升降压电路拓扑中，大功率电感不仅能够有效地存储和释放能量，还能保持电流的连续性，从而避免电流波动对电池充放电过程产生负面影响。

在电流检测方面，采用了 INA188 仪表放大器，它具有非常低的输入偏置电流和高共模抑制比，适合微小电流信号的精确检测。在电池充放电过程中，INA188 与分流电阻配合工作，能够提供准确的电流反馈信号，确保电池充放电的电流精度符合设计要求。

为了确保电池电压的准确测量，系统中使用了 OPA2182 运算放大器对电池的电压信号进行检测。OPA2182 是一款低偏置电流、低噪声、精密的双运算放大器，具有极高的输入阻抗和稳定的电压增益。它的输出信号具有非常高的精度，适合用于电池电压的细微变化检测。OPA2182 的工作电压范围广，能够在各种电压条件下稳定工作，同时其低噪声特性减少了测量误差。

ADS131M08 模数转换器在本设计中用于将模拟信号转换为数字信号，供主控芯片进一步处理。ADS131M08 是德州仪器公司推出的高精度、低功耗的 16 位 ADC，具有高达 32kSPS 的采样速率和极低的噪声性能。其内置的自动增益控

制能够自动调节信号增益,保证在各种输入信号范围内都能提供稳定的转换结果。该 ADC 具备多通道输入、内建时钟发生器、SPI 接口等功能,能够与其他电路组件高效通信,确保电流和电压信号被精确、及时地采集并反馈至系统。

4.3 电路设计

4.3.1 驱动电路设计

在 100A 双相数字电池测试仪的驱动电路中,选用的栅极驱动芯片是 UCC27211DDA。它是一款高性能、隔离型双通道栅极驱动器,专为驱动功率器件而设计,能够满足高电流和高频率的要求。该芯片的特点包括低传播延迟、强带载能力,能够提供高达 4A 的峰值拉电流和 6A 的峰值灌电流。在本研究中,UCC27211DDA 用于控制双相 Buck-Boost 电路中的 MOSFET,确保电池测试仪在充放电过程中具有精确且可靠的电流与电压控制。




图 4-2 驱动电路

图 4-2 中显示的驱动电路由 UCC27211DDA 栅极驱动芯片和相应的外围元件组成。电路中的 PWM 信号由主控芯片 TMS320F280039 提供,经过适当的隔离后,输入到 UCC27211DDA 的 PWM 引脚。该芯片将 PWM 信号转化为高低电平的栅极驱动信号,从而控制 MOSFET 的开关状态。

UCC27211DDA 提供两个独立的输出通道 HO 和 LO,用于分别驱动功率电路中的两路 MOSFET。这些输出信号经由栅极电流驱动器传递给 MOSFET 的栅极,通过调节占空比控制电流流向,从而调节输出电压。

UCC27211DDA 芯片的供电电源分为高压侧和低压侧。高压侧采用 16V 供电电源,提供足够的能量来驱动 MOSFET 栅极的高电平信号;低压侧则采用 3.3V 供电电源,为栅极驱动芯片的控制部分提供所需的电源。

为了驱动上管使用了自举电源结构,包括自举电容和限流电阻。自举电容的选用原则是其电容值通常为 MOSFET 栅极等效电容的十倍,以确保栅极驱动的稳定性和快速响应。栅极等效电容的计算公式如下:

$$C_G = \frac{Q_G}{V_{GS}} \quad (4-1)$$

其中: C_G 为栅极等效电容; Q_G 为栅极的电荷; V_{GS} 为栅极与源极之间的电压。

4.3.2 双相同步 Buck-Boost 电路设计

本设计采用双相同步 Buck-Boost 拓扑结构,通过实时电流采样与 PWM 调节,使用同步整流技术的双向能量流动交错控制实现电池的高精度大电流充放电管理。电路输入电压范围为 12~15V,输出电压可调节至 50mV~6V,单相最大输出电流 50A,每一相的电路完全一致,双相并联后总输出电流可达 100A,满足电池测试场景下极端工况需求。




图 4-3 单相同步 Buck-Boost 电路

如图 4-3 所示,单相电路由四只 CSD17556Q5B MOSFET 构成双管并联结构,其中高侧(Q1、Q4)与低侧(Q2、Q3)各采用双管并联配置。该设计通过降低等效导通电阻将单相导通损耗压缩至:

$$P_{cond} = I_{rms}^2 \cdot R_{DS(on)} = (50)^2 \times 0.85m\Omega = 2.125W \quad (4-2)$$

充电时,电路工作在 Buck 模式,通过调节 PWM 占空比 $D = V_{bat} / V_{in}$ 实现输出电压精确控制。高侧 MOSFET 导通,低侧关断,输入能量通过电感 L 向电

池传输，电感电流线性上升：

$$\frac{dI_L}{dt} = \frac{V_{in} - V_{bat}}{L} \quad (4-3)$$

在关断阶段，Q1、Q4 关断，Q2、Q3 导通，电感 L 通过二极管续流，电流斜率变为：

$$\frac{dI_L}{dt} = -\frac{V_{bat}}{L} \quad (4-4)$$

放电时，电路工作在 Boost 放电模式。电池作为输入源，当低侧 MOSFET 导通时，电感储能：

$$\frac{dI_L}{dt} = -\frac{V_{bat}}{L} \quad (4-5)$$

高侧导通阶段将电感能量释放至负载，电压抬升关系为：

$$V_{out} = \frac{V_{bat}}{1-D} \quad (4-6)$$

同步整流技术将传统续流二极管替换为 MOSFET，缩短了反向恢复时间，提升了效率。基于双相交错结构，通过两路双相驱动同步 Buck-Boost 电路并联工作，实现高效率、低纹波的电池充放电管理。

4.3.3 检测电路设计

（1）电流检测电路

电流检测电路主要用于精确测量电池充放电过程中流经电池的电流。该电流检测部分设计采用精密仪表放大器 INA188IDR，并通过一个 $500\mu\Omega$ 的低值采样电阻来采集电流信号。此电流信号经过放大后送入 ADS131M08 模数转换器，从而实现数字化处理和精确的电流测量。

在图 4-4，INA188IDR 仪表放大器起到了关键作用。通过采样电阻 R_{sense} 产生的电压降将电池充放电过程中的微小电流信号放大，以便于后续的数字转换与处理。在电流检测中，INA188 的增益由反馈电阻 R_{22} 决定，增益公式如下：

$$Gain_I = 1 + \frac{50}{R_{22}} = 1 + \frac{50}{1.15} = 44.48 \quad (4-7)$$

可测量的最大电流为：

$$I_{max} = \frac{V_{ref}}{(Gain_I * R_{sense})} = \frac{1.25}{44.48 * 500\mu} = 56A \quad (4-8)$$

其中, V_{ref} 是 INA188IDR 的基准电压, R_{sense} 是 $500\mu\Omega$ 的采样电阻, 增益的选择确保了电流信号的准确放大, 满足在单相最大电流 50A 时, 能够提供足够的电压输出范围供后续 ADC 转换。




图 4-4 电流检测电路

(2) 电压检测电路

电池电压检测电路用于精确测量充放电时电池端的电压, 并为后续的电池健康度评估提供数据。图中展示的电池电压检测电路使用了 OPA2182AID 运算放大器作为核心组件, 该运算放大器具有高精度、低漂移和低功耗的特点, 适合电池电压的精准测量。




图 4-5 电池电压检测电路

在图 4-5 中, OPA2182AID 运算放大器被配置为一个差分放大器。电池的正负端电压分别通过电阻 R_{49} 和 R_{51} 输入到运算放大器的非反向输入端和反向输入端。这些输入信号经过放大后, 输出到 ADC 模数转换器中进行数字化处理。在该电路中, R_{47} 连接在运算放大器的非反向输入端与参考电压之间用来控制输入电压, 而 R_{55} 作为反馈电阻连接在运算放大器的反向输入端和输出端之间, 与 R_{49}

构成增益比率，决定了输出电压与输入电压的放大倍数。放大增益如下计算，可满足 ADC 的输入要求。

$$Gain_{Uba} = \frac{R_{47}}{R_{49} + R_{47}} \cdot \left(1 + \frac{R_{55}}{R_{51}}\right) = \frac{10}{49.9 + 10} \times \left(1 + \frac{10}{49.9}\right) = 0.2 \quad (4-9)$$

在同步 Buck-Boost 电路电压检测中，使用了 TLV9102IDR 运算放大器，它具备双通道和较宽的电压范围，适用于高精度的电压监测。通过两路独立的检测通道，分别对 Buck-Boost 电路的输入和输出端进行电压检测，减小了体积，降低了电路复杂度，节约了成本。




图 4-6 输入电压检测电路




图 4-7 输出电压检测电路

在电源输入端，TLV9102IDR 用作电压跟随器，输入电压信号先经过 R57 分压后稳定输出，传递到后级的 ADC 进行处理，减少噪声影响。

在电源输出端，输出电压信号经过 R52 和 R50 的分压后输入到 TLV9102IDR 的输入端，通过反馈电阻 R56 计算增益如下：

$$Gain_{Uou} = \frac{R_{48}}{R_{50} + R_{48}} \cdot \left(1 + \frac{R_{56}}{R_{52}}\right) = \frac{20}{49.9 + 20} \times \left(1 + \frac{20}{49.9}\right) = 0.4 \quad (4-10)$$

4.3.4 保护电路设计

本系统保护电路如图 4-8 所示，采用四路并联的功率开关架构与多级硬件保护策略，实现电池测试仪的高可靠性安全防护。电路通过集成隔离驱动、冗余比较逻辑与快速关断机制，可在短时间内响应电压异常、逻辑故障及过流风险，确保系统在极端工况下的安全性。




图 4-8 保护电路

功率开关模块为四条独立支路并联，每路由两只 TI 的 CSD16570Q5B 型号 MOSFET 串联构成，总导通电阻低，且支持电池测试仪的最大持续电流 100A，串联结构将单管电压应力降低，电压耐受能力增强，避免器件被击穿。

选用 TI 的 TPSI3050 隔离驱动器，集成 10V 栅极电源与 4 路独立输出，共模抑制比高，驱动传输延迟低。其使能引脚通过三路信号协同控制，构成硬件互锁保护机制。基准使能信号为 5V 参考电压；电池电压监控信号为电池端电压 V_{bat} 与 -5V 参考电压经 LM393 比较器差分比较输出，当 V_{bat} 超限时，输出低电平；MCU 使能信号是主控芯片输出的数字使能信号与 10V 参考电压经第二路 LM393 比较器比较产生，若 EN_MCU 异常，输出低电平。仅当所有信号为高电平时，

TPSI3050 输出驱动信号，MOSFET 支路导通。

当正常工作时，电池电压在正常范围且 MCU 使能有效， V_{bat} 与 EN_{MCU} 均输出高电平，5V 基准信号使 EN 引脚置高，TPSI3050 输出 10V 栅极电压，四路 MOSFET 同步导通，系统进入低阻抗工作状态。

当系统发生异常时，若 V_{bat} 超限，输出低电平，EN 引脚被强制拉低，TPSI3050 在 200ns 内关断驱动，MOSFET 支路切断电流路径；若 EN_{MCU} 信号异常或 MCU 死机，输出低电平，直接封锁驱动输出；当负载电流超过 MOSFET 安全阈值，串联结构通过均流设计将单管电流限制在 37.5A 以下，结合过温保护避免热失效。从 EN 置低至 MOSFET 完全关断的时间小于 500ns，故障消除后 MCU 通过 SPI 接口复位 TPSI3050 状态寄存器，重新激活驱动信号，恢复时间小于 10ms。

4.3.5 电源电路设计

在电池测试仪的设计中，稳定可靠的电源供给至关重要。图 4-9 展示了 10V 电源模块的电路设计，该模块用于为栅极驱动器供电。此部分电路采用 LMR54410DBVR 开关降压转换器实现从输入电压 V_{HV} 生成稳定的 10V 直流输出。




图 4-9 10V 电源电路

LMR54410DBVR 是一款高效、低功耗的同步降压转换器，其最大输入电压可达 36V，输出电流能力可达 1A，并具备高效率 and 低静态电流的特性，该芯片内部集成了高频开关控制机制，可在 2.1MHz 频率下运行，有助于减小电感和滤波电容的尺寸。输入电压经过滤波电容进行初步稳压，以降低输入端的高频噪声，随后送入 LMR54410DBVR 的输入端端，同时使能引脚连接至高电平，确保芯片

正常工作。开关信号由 SW 端输出，驱动电感并通过肖特基二极管进行整流，再经过输出滤波电容进行平滑处理，从而生成稳定的 10V 直流电压，用以驱动栅极驱动器工作。两个电阻构成电压分压反馈网络，将输出电压反馈至芯片的反馈引脚，以实现精准的输出电压调节。

采用两个独立的 TLV1117-50IDCY 低压差线性稳压器（LDO）从 10V 电压源分别生成 5VA（模拟电压）和 5VD（数字电压），以确保模拟电源与数字电源的隔离，减少数字信号对模拟电路的干扰。




图 4-10 5V 模拟电源电路




图 4-11 5V 数字电源电路

PM-CHP-LM2664M6-6 是一款基于电荷泵架构的负电压转换芯片，在本测试仪电路中其功能是将输入的+5V 模拟电压通过开关电容拓扑高效转换为稳定的-5VA 输出，为电池保护电路中的电压比较器提供高精度负参考电压。如图 4-12 所示。




图 4-12 -5V 模拟电源电路

AVDD（模拟电源）与 DVDD（数字电源）是电子系统中针对模拟和数字电

路独立设计的供电网络，在通过电源隔离与差异化优化，可以提升系统整体性能与抗干扰能力。

TPS73633DBVR 是 TI 针对数字系统优化的 LDO，支持 3.3V 固定输出，最大负载电流 1A。如图 4-13 所示，5VD 输入经 π 型滤波器预处理后，输入至 IN 引脚。反馈引脚通过内部反馈环路动态调节输出电压，使 DVDD 稳定在 3.3V。绿色 LED 直接由 DVDD 驱动，显示电源就绪状态。此电路采用单点接地策略，数字地（DGND）与模拟地通过磁珠隔离，降低瞬态电流对敏感信号的影响。




图 4-13 DVDD 电源电路

TPS7A2033PDBVR 是一款专为模拟电路供电设计的 LDO，其输入电压范围为 1.5V-6.5V，输出电流能力 300mA。如图 4-14 所示，5VA 输入电压经高低频复合滤波器滤除电源噪声后，送入 LDO 的 IN 引脚。R₁₃₉ 与 R₁₄₀ 构成分压网络，配合 NR/FB 引脚实现动态负载调整，输出电压稳定于设定值 AVDD。绿色 LED 通过 R₁₃₈ 限流电阻连接至 AVDD，实时指示电源状态。




图 4-14 AVDD 电源电路

4.4 软件架构与控制环路设计

本设计基于 C2000™微控制器（TMS320F280039）与 DigitalPower SDK 构建

软件系统，通过多级中断服务例程（ISR）实现双相 Buck-Boost 功率级的闭环控制。其核心设计目标为实现 $\pm 20\text{mA}$ 电流调节误差与 $\pm 1\text{mV}$ 电压调节精度，满足动力电池测试的需求。

4.4.1 软件流程设计

软件系统采用模块化架构，主要包含以下功能模块：

1.主程序框架：初始化硬件外设（HRPWM、ADC、SPI 等），配置中断优先级及系统时钟；

2.中断服务例程（ISR）：

ISR3 由 ADCC 转换完成触发，执行输入电压检测与软启动逻辑；ISR4 由外部 ADC 的 DRDY 信号触发，运行电流/电压控制环路；ISR7 处理 SPI 接收 FIFO 中断，实时读取外部 ADC 数据；

3.控制算法库：实现电流模式控制（CMC）与电压-电流级联控制策略；

4.SFRA 工具集成：通过软件频率响应分析器在线调谐控制参数，优化环路稳定性。




图 4-15 软件流程图

软件流程以主程序初始化外设（PWM、ADC、SPI）为启动标志，结合三层中断服务例程完成实时控制。主程序启动后，首先检测外部输入电压，若异常则

触发 LED 报警并锁定系统；当电池电压与设定值偏差超过 50mV 时，系统运行恒流（CC）模式，通过电流环 PI 控制器生成 PWM 占空比；当电压接近设定值时，切换至恒压（CV）模式，电压环输出电流限幅值以实现平滑过渡。实时数据通过从外部 ADS131M08 读取，若 SPI 校验失败，则丢弃数据包并记录错误。系统集成软件频率响应分析器，当使能标志激活时，在线注入扫频信号以优化控制参数。故障监控线程实时检测过温或过流信号后，立即切断输出并上报异常。

4.4.2 控制环路设计

电流环与电压环控制采用级联双闭环结构，通过电流内环与电压外环的协同作用实现高精度功率调节。如图 4-16 所示，电压外环以目标电压 V_{ref} 为输入，与反馈电压 V_{sense} 比较生成误差信号，经 PI 控制器输出电流参考值 I_{ref} ，作为电流内环的设定输入。电流内环则通过分流电阻实时检测电感电流 I_{sense} ，与 I_{ref} 的误差经动态补偿器生成 PWM 占空比指令，驱动双相 Buck-Boost 功率级。

在恒压（CV）模式下，当电池电压接近设定值时，电压环输出限幅电流值，确保平滑过渡至恒压状态；在恒流（CC）模式下，电压环饱和，电流环直接跟踪设定电流。




图 4-16 电流电压控制环路

4.5 设备测试

4.5.1 软件频率响应测试

软件频率响应分析器（Software Frequency Response Analyzer, SFRA）是一种

基于数字信号处理技术的先进测试方法，主要用于电力电子系统控制环路的动态特性分析与优化^[72]。其核心功能在于通过非侵入式测试手段，量化评估闭环系统的稳定性与频域响应特性，为控制器参数设计提供数据支撑。SFRA 的工作原理基于线性系统频域分析理论，通过向控制环路注入低幅值扫频扰动信号并同步采集系统的反馈信号，结合快速傅里叶变换（FFT）算法提取输入输出信号的幅值与相位关系，构建系统开环或闭环传递函数的波特图，最终计算系统的增益裕度（Gain Margin）、相位裕度（Phase Margin）及穿越频率（Crossover Frequency）等关键稳定性指标。

SFRA 将传统硬件测试仪器的功能集成于数字控制平台，采用闭环在线测试模式，通过与开发环境及可视化工具的深度集成，完成了测试数据与补偿器设计的双向交互。本实验采用了 TI C2000™ 系列微控制器编程软件 CCS(Code Composer Studio)中的 SFRA 功能，对电池测试仪的各控制环路进行了测试。

（1）单相电流控制

通过设置占空比基准值实现单相开环电流控制，使用 SFRA 进行测试。将输入电压设定为 12V，输出端接入电子负载模拟电池等效阻抗，电压设定 4.2V。在 CCS 软件中，如图 4-17 所示，在 Sysconfig 页面中设置以下参数。




图 4-17 单相开环电流构建选项

在运行后通过修改结构体中变量手动调节占空比，使输出电流逐步提升至 15A；启用 SFRA 功能，注入扫频信号，采集开环传递函数数据；通过 ADS131M08

同步记录电流采样值与 PWM 占空比，验证开环控制的线性度。

当占空比设定为 3% 时，实测输出电流为 14.89A，相对理论值存在 0.11A 偏差。SFRA 扫频测试如图 4-18 所示，0dB 穿越频率为 7962.14Hz，相位裕度仅 6.66° ，表明原始系统存在稳定性风险。开环控制模式下，系统缺乏实时反馈校正机制，其输出电流受功率级参数漂移、温度变化及负载扰动影响显著。SFRA 波特图显示的相位裕度不足问题，揭示了原始系统在闭环设计时需引入相位补偿的必要性。




图 4-18 电流控制开环频率响应

(2) 双相电流控制

本实验进一步开展双相交错式降压功率级的闭环电流控制实验。将输入总线电压调整为 15V，输出端接入电子负载模拟电池等效阻抗，配有高精度分流器作为反馈元件；如图 4-19 所示，在软件中启用双相协同控制模式，设定全局电流基准值 30A（每相 15A），补偿器参数继承单相实验优化结果；通过 SFRA 注入扫频信号，并利用电子负载施加阶跃扰动评估动态响应；实时监测两相电流传感器数据，计算相位间电流偏差率。




图 4-19 双相电流闭环构建选项

在 30A 全局电流设定下，两相均流误差低于 0.05%，最大瞬时偏差 0.24A。动态测试中，系统在 50%负载阶跃下呈现出调节时间更短、超调量更低且无振荡现象。频域特性分析显示，双相架构使系统带宽扩展至 1.5kHz，相位裕度提升至 157.1° ，增益裕度达 25.74dB。




图 4-20 双相电流控制频率响应

(3) 双相电流电压控制

在双相交错闭环电流控制体系基础上，构建电压-电流级联控制架构，硬件系统集成 OPA2182 精密运算放大器构建电压检测模块，软件层面通过实时电压

监测触发模式的切换。按照如图 4-21 所示进行参数配置，通过可编程电子负载模拟电池电压从深度放电态至满充态的渐变过程，系统执行检测校准。




图 4-21 双相电压电流构建选项

实验结果如图 4-22 所示，系统在 12619.15Hz 高频段呈现 28.65dB 的幅度增益与 -43.01° 相位延迟，相位裕度达 79.44° ，增益裕度达 15.41dB；高频处的衰减与平滑相位曲线保障了模式切换过程的电流斜率受控性及能量回馈效率。




图 4-22 双相电流电压控制闭环频率响应

4.5.2 实物测试

经过软件测试后，进行了实物实验平台的搭建。实物平台如图 4-23 所示，主系统由电池测试仪、软包锂电池、上位机及示波器构成闭环测试体系。测试仪采用四层 PCB 堆叠设计，实验所用的软包锂电池是浙江南都生产的磷酸铁锂电池，额定容量 64Wh，额定容量 20Ah，标称电压 3.2V，充电截止电压 3.6V，放电截止电压 2.5V。




图 4-23 硬件测试平台

使用 TMS320F280039C 控制板为主控制器，进行控制信号的输出与反馈信号的接受，在 CCS(Code Composer Studio)V12.8.1 进行程序编写，实验代码通过 XDS110 仿真器烧录至存储器，启用 CCS 的实时变量观察功能，将各变量实时显示。

表达式	类型	值	地址
BT2PH_labNumber	enum <unnamed>	Lab4_ClosedLoopDualPhase_CCCV	0x0000C5E4@Data
BT2PH_SfraStatus	enum <unnamed>	SFRA_Disabled	0x0000C5E5@Data
BT2PH_CalibrationStatus	enum <unnamed>	Calibration_Disabled	0x0000C5E6@Data
BT2PH_CalibrationMode	enum <unnamed>	0	0x0000C5E7@Data
BT2PH_InputVoltageSense_V	float	12.3132324	0x0000C5E8@Data
BT2PH_enableRelay_bool	unsigned int	0	0x0000C001@Data
BT2PH_userParam_V1_ch1	struct <unnamed>	(iref_A=60.0,vrefCharge_V=3.5999999,vref...	0x0000C09C@Data
iref_A	float	60.0	0x0000C09C@Data
vrefCharge_V	float	3.5999999	0x0000C09E@Data
vrefDischarge_V	float	2.5	0x0000C0A0@Data
dir_bool	unsigned int	1	0x0000C0A2@Data
en_bool	unsigned int	0	0x0000C0A3@Data
dutyRef_pu	float	0.00999999978	0x0000C0A4@Data
ibatCal_pu	float	0.0	0x0000C0A6@Data
vbatCal_pu	float	0.0	0x0000C0A8@Data
icoutGain_pu	float	0.0185729992	0x0000C0AA@Data
icoutOffset_pu	float	0.000677544624	0x0000C0AC@Data
icoutGain_A	float	53.8416023	0x0000C0AE@Data
icoutOffset_A	float	-0.0364800878	0x0000C0B0@Data
vbatGain_pu	float	0.167084396	0x0000C0B2@Data
vbatOffset_pu	float	0.000334143639	0x0000C0B4@Data
vbatGain_V	float	5.98499918	0x0000C0B6@Data
vbatOffset_V	float	-0.00199984945	0x0000C0B8@Data
BT2PH_measureMultiphase_V1	struct <unnamed>	(Isense1_A=-0.0364800878,Isense2_A=-0....	0x0000C100@Data
Isense1_A	float	-0.0364800878	0x0000C100@Data
Isense2_A	float	-0.0329196341	0x0000C102@Data

图 4-24 参数变量表

如图 4-24 所示，设定恒流模式目标电流（iref_A）、充电恒压阈值（vrefCharge_V）及放电恒压阈值（vrefDischarge_V）为电流/电压参考基准；通过方向标志（dir_bool）、使能开关（en_bool）及占空比标么值（dutyRef_pu）设置运行模式；基于电流增益（ioutGain_A）与偏移量（ioutOffset_A）、电压增益（vbatGain_V）与偏移量（vbatOffset_V）的定量补偿消除传感器非线性误差及 ADC 量化偏差。

硬件平台搭建完成后对软包电池进行了充放电测试。以 3C（60A）电流进行恒流充电，1C（20A）电流放电，以模拟现实中锂电池的使用场景。恒流充电阶段的电压、电流实测波形如图 4-25、图 4-26 所示。




图 4-25 恒流充电电池电压




图 4-26 恒流充电电池电流

完整充放电过程由测试仪主控芯片 TMS320F280039 实时记录数据，导出后经上位机描点作图，呈现完整的电压、电流曲线。




图 4-27 3C 充电 1.5C 放电测试电压曲线




图 4-28 3C 充电 1.5C 放电测试电流曲线

如图 4-27、图 4-28 所示，上位机记录的电压电流曲线显示：在恒流充电阶段，系统极速完成 60A 升流，稳态纹波峰峰值小于 0.5A，驱动电压从 2.5V 快速上升至 3.35V；放电阶段电流以 -30A 恒定输出，切换过程无过冲现象，电压先平缓下降至 3.1V 再快速下降至 2.5V。整体测试结果符合对锂电池进行充放电的一般现象，证明测试仪具备电压电流跟踪能力与电流动态响应特性。

4.6 本章小结

本章系统阐述了电池测试仪的设计实现，涵盖硬件架构、电路模块及控制策略。基于 TMS320F280039 主控芯片构建控制核心，采用双相 Buck-Boost 拓扑与

高效功率器件实现 100A 双向能量转换,利用高精度仪表放大器与运算放大器(O完成电流、电压信号检测,并通过 Δ - Σ ADC 实现模拟信号数字化。电路设计采用双相交错控制策略有效抑制纹波电流,集成隔离驱动与多级硬件保护机制,确保系统可靠性。软件层面通过双闭环控制实现充放电模式动态切换,结合实时中断服务与高分辨率 PWM 优化控制精度与响应速度。在完成硬件搭建与软件配置后,对电池测试仪进行了测试,满足大电流、小误差的需求,测试结果表明了测试仪电路设计的正确性。

第5章 总结与展望

5.1 全文总结

本研究围绕锂离子电池健康状态估计，提出了一种基于萤火虫算法（FA）优化门控循环单元（GRU）神经网络的 SoH 预测方法，并设计了一款双相同步 Buck-Boost 电池测试仪，以获取预测所需的电压、电流、时间等数据。

论文首先介绍了锂离子电池在新能源交通、储能系统等领域的广泛应用及健康状态评估的重要性。查阅了国内外对于锂电池健康状态估计研究及目前的电池检测设备技术的相关内容，选择了数据驱动方法作为技术路径，明确了锂电池测试仪的技术目标。

其次论文系统分析了锂电池的基本构造、工作原理及衰退机理，并通过混合功率脉冲测试及不同倍率充放电测试，深入研究了锂电池的健康状态演变特性。在此基础上，选取了恒流充电时间（CCCT）和恒压充电时间（CVCT）作为 SoH 估计的特征量，并提出了根据电池初始荷电状态选择不同输入特征的策略，以提升预测的时间经济性。

针对传统 GRU 模型在 SoH 预测中的参数调优问题，本研究引入 FA 优化算法，提升模型的全局搜索能力并优化超参数选择。研究过程中首先对原始数据进行奇异值分解（SVD）降噪、小波变换（WT）降噪及归一化预处理，然后构建基于 GRU 的 SoH 预测模型，并利用 FA 搜索最优超参数组合。通过 CALCE 电池老化数据集的实验验证，SVD-FA-GRU 模型在预测精度方面优于传统 GRU、LSTM 和 SVD--GRU 模型，同时结合输入特征的优化策略有效降低了数据需求，提高了预测效率。

为了验证预测模型的可行性并获取高精度实验数据，设计了一款高精度双相 100A 电池测试仪。测试仪硬件部分采用 TMS320F280039 作为主控芯片，结合 MOSFET 功率开关管、精密仪表放大器、运算放大器及高精度 ADC，确保电流、电压的精准测量。电路设计部分涵盖驱动电路、双相同步 Buck-Boost 电路、电流电压检测电路、保护电路及电源电路，各模块协同工作以保证系统的高效性与

安全性。此外，对双相同步 Buck-Boost 架构的电流环路、电压环路进行了设计优化，提高相应快速性和精密性。利用 SFRA 测试控制环路稳定性，随后搭建包含锂电池、测试仪、示波器及上位机的实验平台，开展 3C 充电、1.5C 放电的真实工况实验，结果表明测试仪能够精准采集电池充放电数据，为 SoH 估计记录准确数据，同时具备良好的动态响应性能和稳定性。

5.2 研究展望

（1）本研究的 SVD-FA-GRU 模型在 CALCE 电池数据集中表现优秀，但在更广泛的电池类型及使用场景下的适应性仍需进一步研究。未来可结合迁移学习、增量学习等方法，提升模型的泛化能力，使其适用于不同品牌、不同使用条件的锂电池。

（2）当前模型在保证高精度的同时，仍存在一定计算开销，未来可通过轻量化神经网络或优化硬件加速策略降低计算资源需求，提高实时性，使其适用于嵌入式或车载系统。

（3）当前测试仪主要用于数据采集，未来可结合智能算法，实现电池充放电过程的动态优化控制。此外，可拓展支持多通道测试、无线数据传输及云端数据分析，提高测试仪的智能化程度，以适应工业级应用需求。

（4）目前实验仅在实验室环境下进行，未来可将测试仪应用于电动汽车、电网储能等实际工况，通过长时间运行验证系统的可靠性与鲁棒性。同时，结合更多实际电池数据集，以进一步评估模型的工程适应性。

参考文献

- [1] 王佳, 孟顺. 发展新能源汽车保障我国能源安全的路径研究[J]. 汽车实用技术, 2020, (04): 7-9.
- [2] 韦增欣, 黄海东, 袁功林. 新能源汽车电池发展潜力与未来趋势探索[J]. 时代汽车, 2024, (07): 73-75.
- [3] 中国汽车动力电池产业创新联盟. 2023 年动力电池产业数据快报[R]. 北京: 中国汽车动力电池产业创新联盟, 2024.
- [4] 高工锂电(GGII). 2023 年中国锂电池行业年度报告[R]. 深圳: 高工产业研究院, 2024.
- [5] 谢鹏. 浅析新能源汽车动力电池的维护与保养[J]. 内燃机与配件, 2021, (18): 170-171.
- [6] 陈彦余. 考虑评估状态的退役锂离子电池在微电网的经济性优化应用[D]. 长沙理工大学, 2021.
- [7] 王琢璞. 新能源汽车动力电池回收利用潜力及生命周期评价[D]. 清华大学, 2018.
- [8] 范凌峰. 锂离子电池健康状态估计与退役电池分选重组方法研究[D]. 天津大学, 2022.
- [9] Dong H C, Jin X N, Lou Y B, et al. Lithium-ion battery state of health monitoring and remaining useful life prediction based on support vector regression-particle filter[J]. Journal of Power Sources, 2014, 271: 114-123.
- [10] Berecibar M, Gandiaga I, Villarreal I, et al. Critical review of state of health estimation methods of Li-ion batteries for real applications[J]. Renewable & Sustainable Energy Reviews, 2016, 56: 572-587.
- [11] Kim J, Cho B H. State-of-charge estimation and state-of-health prediction of a Li-ion degraded battery based on an EKF combined with a per-unit system[J]. IEEE Transactions on Vehicular Technology, 2011, 60(9): 4249-4260.
- [12] Chaoui H, Golbon N, Hmouz I, et al. Lyapunov-based adaptive state of charge and

- state of health estimation for lithium-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2015, 62(3): 1610-1618.
- [13]赵鑫浩. 基于数据驱动的动力锂离子电池健康状态估计和剩余使用寿命预测[D]. 天津理工大学, 2024.
- [14]赵轩, 李美莹, 余强等. 电动汽车动力锂电池状态估计综述[J]. 中国公路学报: 1-39[2023-04-21].
- [15]武龙星, 庞辉, 晋佳敏等. 基于电化学模型的锂离子电池荷电状态估计方法综述[J]. 电工技术学报, 2022, 37(07):1703-1725.
- [16]Ng K S, Moo C S, Chen Y P. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries[J]. Applied Energy, 2009, 86(9): 1506-1511.
- [17]Chu A, Allam A, Arenas A, et al. Stochastic capacity loss and remaining useful life models for lithium-ion batteries in plug-in hybrid electric vehicles[J]. Journal of Power Sources, 2020, 478: 228991.
- [18]金帅, 董静. 基于数据驱动的动力锂离子电池健康状态估计研究进展综述[J]. 仪器仪表学报, 2024, 45(03): 45-59.
- [19]丁恒, 黄凯, 田海建. 基于 VMD 和 ISSA-ELM 的动力锂离子电池剩余使用寿命预测[J]. 电源学报, 2024, 22 (06): 188-198.
- [20]李锦满, 李儒欢, 李浩南等. 基于无迹卡尔曼滤波的动力电池状态估计[J]. 电池, 2024, 54 (03): 340-343.
- [21]高昕, 韩嵩. 基于分数阶模型的锂离子电池 SOC 与 SOH 协同估计[J]. 电源技术, 2021, 45(09): 1140-1143+1208.
- [22]张成. 基于改进无迹卡尔曼滤波算法的动力锂离子电池 SOC 和 SOH 联合估计[D]. 吉林大学, 2023.
- [23]赵月荷, 庞宗强. 基于无迹卡尔曼滤波的动力电池健康状态估计[J]. 国外电子测量技术, 2022, 41(10): 136-141.
- [24]Diaconis P. Sequential Monte Carlo methods in practice[J]. Journal of the American Statistical Association, 2003, 98(462): 496-497.
- [25]徐超, 李立伟, 杨玉新等. 基于改进粒子滤波的锂电池 SOH 预测[J]. 储能科

- 学与技术, 2020, 9(06): 1954-1960.
- [26] Bi Y, Yin Y, Choe S. Online state of health and aging parameter estimation using a physics-based life model with a particle filter. *Journal of Power Sources*, 2020, 476: 228655.
- [27] 姚远. 基于数据驱动的锂电池健康状况和剩余寿命预测方法研究[D]. 福州大学, 2021.
- [28] 刘晓悦, 魏宇册. 优化神经网络的锂电池 SOC 估算[J]. *机械设计与制造*, 2021(11): 83-86.
- [29] 李旭东, 张向文. 基于主成分分析与 WOA-Elman 的锂离子电池 SOH 估计[J]. *储能科学与技术*, 2022, 11(12): 4010-4021.
- [30] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J]. *高电压技术*, 2024, 50(03): 1182-1195.
- [31] 杨号远. 退役动力锂离子电池检测及回收技术研究[D]. 武汉理工大学, 2021.
- [32] 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.
- [33] 苑春迎, 耿家锐. 基于 SOA 架构的纯电动汽车电源管理系统设计[J]. *汽车测试报告*, 2024, (01): 19-21.
- [34] 杨杰, 解晶莹, 晏莉琴等. 锂离子电池健康状态估计方法[J]. *电池*, 2019, 49(03): 247-250.
- [35] 张绍虹. 电动汽车锂离子电池 SOH 估算方法研究[D]. 太原理工大学, 2019.
- [36] Pan H H, Lu Z Q, Lin W L, et al. State of charge estimation of lithium-ion batteries using a grey extended Kalman filter and a novel open-circuit voltage model[J]. *Energy*, 2017, 138: 764-775.
- [37] 马悦. 电动汽车电池信息采集系统的设计与实现[D]. 哈尔滨工业大学, 2019.
- [38] 崔相雨. 基于嵌入式 MCU 的车载动力锂电池管理系统关键技术研究[D]. 湖南大学, 2019.
- [39] Chen SZ, Liang Z, Yuan H, Yang L, et al. A novel state of health estimation method for lithium-ion batteries based on constant-voltage charging partial data and convolutional neural network, [J]. *Energy*, 2023, 283:129103.
- [40] 欧阳明高, 卢兰兰, 冯旭宁. 基于超声导波的锂离子电池电极膨胀实时检测

- 方法[J]. 储能科学与技术, 2023, 12(5): 1432-1440. DOI:10.19799/j.cnki.2095-4239.2023.0121.
- [41]周宇昊, 徐楞赞, 张钟平等. 基于数字孪生的锂电池热电耦合模型构建与仿真分析[J]. 储能科学与技术, 2023, 12(02): 536-543.
- [42]中华人民共和国工业和信息化部. 动力电池检测设备通用技术要求: GB/T 43241-2023[S]. 北京: 中国标准出版社, 2023: 6-8.
- [43]广豪. 动态工况下锂离子动力电池荷电状态估计和健康状态预测[D]. 长安大学, 2023.
- [44]解清波. 汽车锂离子动力电池健康状态估计方法研究[D]. 东北林业大学, 2021.
- [45]赵鑫浩. 基于数据驱动的动力锂离子电池健康状态估计和剩余使用寿命预测[D]. 天津理工大学, 2024.
- [46]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.
- [47]Li Y, Zhang Q, Wang H, et al. A Comprehensive Review of Internal Resistance Modeling and State Estimation of Lithium-Ion Batteries[J]. Renewable and Sustainable Energy Reviews, 2022, 173: 113156.
- [48]贾振华. 锂电池荷电状态与健康状态预测方法研究[D]. 中北大学, 2024.
- [49]康明仁. 电动汽车锂离子电池荷电状态估计方法研究[D]. 天津工业大学, 2019.
- [50]Luo Y X, Gao X Y, Dong M J, et al. Exploring the structural properties of cathode and anode materials in Li-ion battery via neutron diffraction technique[J]. Chinese Journal of Structural Chemistry, 2023, 42(5): 0254-5861.
- [51]Behl W K, Chin D T. Electrochemical overcharge protection of rechargeable lithium batteries: I. Kinetics of iodide/tri-iodide/iodine redox reactions on platinum in solutions[J]. Journal of the Electrochemical Society, 2019, 135(1): 16-16.
- [52]乔家璐. 基于萤火虫优化算法的锂电池 SOC 与 SOH 协同估计研究[D]. 西南科技大学, 2023.
- [53]李欢, 王顺利, 邹传云等. 基于 Thevenin 模型和自适应卡尔曼的 SOC 估算研究[J]. 自动化仪表, 2021, 42(01): 46-51.

- [54]柳佩文. 车用锂离子电池热管理系统结构优化与实验研究[D]. 重庆交通大学, 2021.
- [55]Zhang C, Wang L, Liu Y, et al. Energy loss analysis for fast-charging lithium-ion batteries[J]. Journal of Power Sources, 2020, 477: 228715.
- [56]徐超. 车载动力锂电池 SOH 估计研究[D]. 青岛大学, 2021.
- [57]张涵. 基于多特征健康因子的锂离子电池 SOH 预测研究[D]. 中北大学, 2023.
- [58]李建林, 李雅欣, 陈光等. 退役动力电池健康状态特征提取及评估方法综述[J]. 中国电机工程学报, 2022, 42 (04): 1332-1347.
- [59]胡慧敏. 车用锂离子电池健康状态估计及剩余寿命预测[D]. 长安大学, 2020.
- [60]Ting T ,Huimei Y .The capacity prediction of Li-ion batteries based on a new feature extraction technique and an improved extreme learning machine algorithm[J]. Journal of Power Sources, 2021, 514: 230604.
- [61]Tian X J, Li X X, Wang H Y, et al. Intelligent online health estimation for lithium-ion batteries based on a parallel attention network combining multivariate time series[J]. Frontiers in Energy Research, 2022, 10: 987654.
- [62]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.
- [63]Deng Y, Ying H, E J, et al. Feature parameter extraction and intelligent estimation of the state-of-health of lithium-ion batteries[J]. Energy, 2019, 176: 91-102.
- [64]Wang Z, Zeng S, Guo J, et al. State of health estimation of lithium-ion batteries based on the constant voltage charging curve[J]. Energy, 2019, 167: 661-669.
- [65]Serra A, Ortiz A, Manjarrés D, et al. SpeCluRC-NTL: Spearman's distance-based clustering reservoir computing solution for NTL detection in smart grids[J]. International Journal of Electrical Power & Energy Systems, 2025, 25: 100522.
- [66]Kurniati A B, Bakar M A, Ibrahim N F, et al. Enhancing artificial neural network learning efficiency through singular value decomposition for solving partial differential equations[J]. Results in Applied Mathematics, 2024, 157: 109891.
- [67]Kalman D. A singularly valuable decomposition: the SVD of a matrix[J]. The College Mathematics Journal, 1996, 27(1): 2-23.

- [68]张婷婷, 于明, 李宾等. 基于 Wavelet 降噪和支持向量机的锂离子电池容量预测研究[J]. 电工技术学报, 2020, 35(14): 3126-3136.
- [69]赵鑫浩, 许亮. 改进的萤火虫算法优化反向传播神经网络动力锂离子电池健康状态估计[J]. 储能科学与技术, 2023, 12(03): 934-940.
- [70]Chung J, Gülçehre Ç, Cho K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. CoRR, 2014, abs/1412.3555.
- [71]Smith J. High-Frequency SiC Inverters for Electric Aircraft: Performance Evaluation and Thermal Management[J]. Applied Energy, 2023, 339: 121567.
- [72]Kim S, Park T, Müller J. Real-time optimization of power converter control parameters via software-based frequency response analysis[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2023, 11(2): 1567-1580.

攻读硕士期间取得的学术成果

- [1] Health State Estimation Method of Lithium-Ion Batteries Based on Firefly Algorithm Optimization [C]// 2025 7th International Conference on Information Science, Electrical and Automation Engineering (ISEAE). Haerbin, China, 2024.

致谢

时光荏苒，我的硕士生涯已接近尾声。这三年的时光既漫长又短暂，其中充满了酸甜苦辣，更有收获和成长。感谢三年来陪我一起度过美好时光的每一位尊敬的老师和亲爱的同学，正是你们的帮助，我才能克服困难，正是你们的指导，我才能解决疑惑，直到学业的顺利完成。

本人的学位论文是在我的恩师陈其工教授的殷切关怀和耐心指导下进行并完成的，衷心感谢我的恩师对我的谆谆教诲和悉心关怀。从课题的选择、项目的实施，直至论文的最终完成，陈教授都始终给予我耐心的指导和支持。恩师开阔的视野、严谨的治学态度、精益求精的工作作风，深深地感染和激励着我，在此谨向陈教授致以衷心的感谢和崇高的敬意。

感谢实验室的师兄师弟师妹们与我一道分享他们青春的快乐！在感谢你们在平时展开的相关工作中给予的一切支持与协助。感谢我的伙伴们，在实验过程和论文写作过程中提供的热心帮助，没有你们就没有这篇论文的顺利完成。

感谢安徽工程大学 22 级硕士班的全体同学陪我一起走过这段人生难忘的历程！

最后，我要向百忙之中参与审阅、评议本论文各位老师、向参与本人论文答辩的各位老师表示由衷的感谢！

人生的每个阶段都值得好好珍惜，这段美好岁月，因为有你们的关心和帮助，我很幸福。我会更加勤奋学习、认真研究，我会努力做得更好，报答祖国，造福社会。把最美好的祝福献给你们，愿永远健康、快乐！