

分类号: TM91

学校代码: 10363

密 级: 公开

学 号: 2210330128



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题目 基于融合数据驱动方法的锂电池健康状态预测研究

论文作者 孙超
校内导师 刘世林 教授
校外导师 程利军 高级工程师
专业学位类别 电子信息
研究方向(领域) 检测技术与自动化装置

论文提交日期: 2024 年 05 月 31 日

分类号: TM91

单位代码: 10363

密 级: 公开

学 号: 2210330128

题 目 基于融合数据驱动方法的锂电池
健康状态预测研究

题 目 Research on State of Health Prediction of
Lithium Battery Based on Fusion Data-driven
Method

学生姓名: 孙超

校内导师: 刘世林 教授

校外导师: 程利军 高级工程师

专 业: 电子信息

研究方向: 检测技术与自动化装置

论文答辩日期: 2024 年 05 月 24 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：孙超

日期：2024年05月31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： 孙超

指导教师签名： 

日期： 2024 年 05 月 31 日

日期： 2024 年 05 月 31 日

基于融合数据驱动方法的锂电池健康状态预测研究

摘要

随着社会经济的快速发展，世界各国都面临着环境污染和能源紧缺的问题，大力发展新能源，实现能源的可持续发展已成为共识。锂电池具有能量密度高、循环寿命长以及环保等诸多优势，已被广泛应用于电动汽车、电子产品和储能等领域中。但锂电池在实际应用中充放电循环会对其健康状态（State of Health, SOH）造成不可逆的衰减，从而影响锂电池的安全稳定运行。因此，准确预测锂电池 SOH 具有极其重要的工程意义。

本文在国内外已有研究成果的基础上，提出了一种基于融合数据驱动方法的锂电池 SOH 预测模型，不仅能够显著提升锂电池 SOH 预测的精度，而且还具有较强的鲁棒性。主要研究内容如下：

（1）针对锂电池在实际应用中放电过程随机性较强的情况，本文研究了从相对规律的锂电池充电片段中提取与 SOH 强相关性的健康特征，并通过定性和定量的方式评估健康特征与 SOH 的相关程度。评估结果表明，等压升充电时间、容量增量曲线的峰值、容量增量曲线的峰面积以及循环次数 4 个健康特征均与 SOH 存在较强的相关性，能够适用于 SOH 的预测。

（2）以提取的健康特征为输入，锂电池 SOH 为输出，构建了一种蚁狮优化的多核相关向量机（Ant Lion Optimization and Multi-Kernel Relevance Vector Machine, ALO-MKRVM）模型，并利用马

里兰大学高级生命周期工程中心（Center for Advanced Life Cycle Engineering, CALCE）的公开数据集以及实验室测试数据进行了实验研究。实验结果表明，ALO-MKRVM 模型相比于 BP 神经网络、支持向量回归、相关向量机以及 MKRVM 模型，各项评价指标均是最优，验证了 ALO-MKRVM 模型的有效性和准确性。

（3）为进一步提高 SOH 的预测精度，提出了一种基于融合数据驱动方法的预测模型。该模型首先利用 ALO-MKRVM 模型生成初始预测值，然后采用蚁狮优化的极限学习机（Ant Lion Optimization and Extreme Learning Machine, ALO-ELM）模型建立 SOH 误差补偿模型，对 ALO-MKRVM 模型的初始预测值进行误差补偿，得到最终的 SOH 预测值。最后，通过 CALCE 数据集和实验室测试数据进行实验验证。实验结果表明，引入误差补偿后得到的 ALO-MKRVM-ELM 模型能够准确预测锂电池老化过程中的容量再生现象，并且相较于其它模型具有更高的预测精度和更强的鲁棒性。

关键词：锂电池，健康状态，多核相关向量机，极限学习机，误差补偿

RESEARCH ON STATE OF HEALTH PREDICTION OF LITHIUM BATTERY BASED ON FUSION DATA-DRIVEN METHOD

ABSTRACT

With the rapid development of social economy, all countries in the world are faced with the problems of environmental pollution and energy shortage, and vigorously develop new energy to achieve sustainable development of energy has become a consensus. Lithium battery has many advantages, such as high energy density, long cycle life and environmental protection, and has been widely used in electric vehicles, electronic products and energy storage fields. However, the charge and discharge cycles of lithium battery in practical applications will cause irreversible attenuation of its state of health (SOH), thus affecting the safe and stable operation of lithium battery. Therefore, accurate prediction of lithium battery SOH has extremely important engineering significance.

In this paper, based on the existing research results at home and abroad, a lithium battery SOH prediction model based on the fusion data-driven method is proposed, which can not only significantly improve the prediction accuracy of lithium battery SOH, but also has strong robustness. The main research content is as follows:

- (1) Aiming the situation that at the strong randomness of the discharge

process of lithium battery in practical applications, this paper studies the extraction of health features that are strongly correlated with the SOH from relatively regular charging segments of lithium battery, and evaluates the degree of correlation between the health features and the SOH by qualitative and quantitative methods. The evaluation results show that the four health features of the equal voltage rise charge time, the peak of the capacity increment curve, the peak area of the capacity increment curve, and the number of cycles are strongly correlated with the SOH, and can be used to predict the SOH.

(2) With the extracted health features as input and lithium battery SOH as output, an ant lion optimization and multi-kernel relevance vector machine (ALO-MKRVM) model is constructed, and experimental studies are conducted using a publicly available dataset from the Center for Advanced Life Cycle Engineering (CALCE) at the University of Maryland, as well as laboratory test data. The experimental results show that the ALO-MKRVM model is optimal compared with BP neural network, support vector regression, relevance vector machine, and MKRVM model in all evaluation indexes, which verifies the effectiveness and accuracy of the ALO-MKRVM model.

(3) In order to further improve the prediction accuracy of SOH, a prediction model based on the fusion data-driven method is proposed. The model first generates an initial predicted value using the ALO-MKRVM

model, and then builds a SOH error compensation model using the ant lion optimization and extreme learning machine (ALO-ELM) model, which compensates the initial predicted value of the ALO-MKRVM model to obtain the final SOH predicted value. Finally, the CALCE dataset and laboratory test data are used for experimental verification. The experimental results show that the ALO-MKRVM-ELM model obtained by introducing error compensation can accurately predict the capacity regeneration phenomenon in the aging process of lithium battery, and has higher prediction accuracy and stronger robustness than other models.

Sun Chao (Electronic Information)

Supervised by Prof. Shilin Liu

KEY WORDS: lithium battery, state of health, multi-kernel relevance vector machine, extreme learning machine, error compensation

目录

摘要.....	I
ABSTRACT.....	III
第 1 章 绪论.....	1
1.1 课题研究背景及意义.....	1
1.2 国内外研究现状.....	2
1.2.1 锂电池健康状态定义.....	2
1.2.2 锂电池 SOH 预测方法.....	2
1.3 论文主要内容与章节安排.....	7
第 2 章 锂电池老化因素分析及数据来源.....	9
2.1 引言.....	9
2.2 锂电池基本结构和工作原理.....	9
2.3 锂电池老化因素分析.....	11
2.3.1 内部因素.....	11
2.3.2 外部影响因素.....	12
2.4 实验室测试数据.....	12
2.4.1 测试平台.....	12
2.4.2 数据测试步骤.....	14
2.5 CALCE 数据集.....	16
2.6 本章小结.....	17
第 3 章 锂电池健康特征的提取及相关性验证.....	18
3.1 引言.....	18
3.2 健康特征提取.....	18
3.3 相关性验证.....	23
3.3.1 定性评估.....	23
3.3.2 定量评估.....	25
3.4 本章小结.....	26
第 4 章 基于 ALO-MKRVM 的锂电池 SOH 预测.....	27
4.1 引言.....	27
4.2 典型预测模型.....	27

4.2.1 BP 神经网络.....	27
4.2.2 支持向量回归	28
4.2.3 相关向量机	30
4.3 ALO-MKRVM 模型的基本原理	32
4.3.1 蚁狮优化算法原理	32
4.3.2 MKRVM 模型	34
4.3.3 ALO-MKRVM 模型的预测流程	35
4.4 实验验证及分析	37
4.4.1 模型参数设置	37
4.4.2 性能评价指标	37
4.4.3 50%训练集仿真结果与分析	38
4.4.4 40%训练集仿真结果与分析	41
4.5 本章小结	45
第 5 章 基于融合数据驱动方法的锂电池 SOH 预测	46
5.1 引言	46
5.2 极限学习机基本原理	46
5.3 基于 ALO-MKRVM-ELM 的 SOH 融合预测模型	47
5.3.1 基于 ALO-ELM 的 SOH 误差补偿模型	47
5.3.2 ALO-MKRVM-ELM 融合模型的预测流程	48
5.4 实验验证及分析	50
5.4.1 模型参数设置	50
5.4.2 基于单节电池数据的有效性验证	50
5.4.3 基于多节电池数据的鲁棒性验证	55
5.4.4 对比实验验证	58
5.5 本章小结	61
第 6 章 总结与展望	62
6.1 全文工作总结	62
6.2 工作展望	63
参考文献	64
攻读硕士期间取得的学术成果	71
致谢	72

第 1 章 绪论

1.1 课题研究背景及意义

自第二次工业革命以来，世界工业化水平迅速提升，世界各国对于化石能源的需求日益增加，导致了能源短缺和环境污染等问题^[1]。面对这些日趋严重的问题，世界各国一方面应用科学技术手段不断提高化石能源的利用效率，另一方面积极推广和应用新能源技术，以逐步替换传统的化石能源。

目前，由于新能源电动汽车技术得到突破性发展，世界各国都意识到通过普及新能源电动汽车来替换传统燃油车，能够在很大程度上解决能源短缺和环境污染等问题^[2]。根据 EVTank 的调查数据显示，2023 年全球范围内新能源电动汽车销量高达 1465.3 万辆，同比增长 35.4%。锂电池作为新能源电动汽车动力系统最重要的组成部分，需求量也日益增多。然而，由于近年来锂电池导致的电动汽车安全事故层出不穷，其安全性问题已逐渐引起人们的高度重视和广泛关注^[3-4]。锂电池性能老化是引发这些安全事故的重要原因之一。随着锂电池长时间的使用，性能会逐渐下降，最直观的表现就是锂电池内阻增大，放电容量减少。老化后的锂电池会出现鼓包、漏液以及局部短路等现象，在使用过程中存在着严重的安全隐患^[5]。电池管理系统（Battery Management System, BMS）作为新能源电动汽车中不可或缺的组成部分，可以通过采集电池运行时的电压、电流以及温度等参数并加以评估，确保锂电池在不正常运行时及时干预^[6-7]。

锂电池健康状态（State of Health, SOH）可用来定量表示锂电池的老化程度，其是 BMS 保证锂电池安全稳定运行的重要参数之一。在实际应用中，过早的更换锂电池会造成资源的浪费，过晚的更换锂电池会存在着极大的安全隐患。因此，BMS 准确把握 SOH 的变化，一方面可以为及时维护和更换锂电池提供重要参考，以便在锂电池故障前及时采取措施^[8]。另一方面，准确的 SOH 可以更全面的了解锂电池状态，提高锂电池的使用效率^[9]。因此，锂电池 SOH 准确预测方法的研究，对提高锂电池安全性、最大程度的使用锂电池以及避免资源浪费具有重要意义。

1.2 国内外研究现状

1.2.1 锂电池健康状态定义

锂电池 SOH 是用来判断电池老化程度的关键参数之一，它可以直观地反映电池当前的健康状态。目前，关于锂电池 SOH 的定义通常是基于容量的方式或者基于内阻的方式^[10]。

基于内阻的方式定义锂电池的 SOH，如式（1-1）所示：

$$SOH = \frac{R_{EOL} - R_{NOW}}{R_{EOL} - R_{NEW}} \times 100\% \quad (1-1)$$

式中， R_{EOL} 为寿命结束时的电池内阻； R_{NOW} 为当前状态下的电池内阻； R_{NEW} 为电池的额定内阻。

基于容量的方式定义锂电池的 SOH，如式（1-2）所示：

$$SOH = \frac{Q_{MAX}}{Q_N} \times 100\% \quad (1-2)$$

式中， Q_{MAX} 为当前电池的最大放电容量； Q_N 为电池的额定容量。

随着锂电池长时间的使用，其老化程度逐渐加深，从而导致电池内阻不断增大，电池的放电容量不断减少。在电池老化前期，电池内阻的变化很小，而在电池老化后期，电池内阻的变化较大。因此采用基于内阻的方式定义锂电池 SOH，极易受到测量误差的影响，导致 SOH 预测精度较低。目前，国内外学者大多是采用基于容量的方式展开对锂电池 SOH 的研究^[11-12]。因此，本文也采用基于容量的方式定义锂电池 SOH。

1.2.2 锂电池 SOH 预测方法

随着锂电池在新能源汽车、储能等领域的广泛应用，SOH 的预测问题已成为了国内外学者研究的热点。因此，衍生出了一系列关于锂电池 SOH 的预测方法，其主要可分为 4 种，分别为直接测量法^[13]、基于模型的方法^[14-15]、基于数据驱动的方法^[16-17]以及基于融合模型的方法^[18-19]。典型的预测方法如图 1-1 所示。




图 1-1 典型锂电池 SOH 预测方法分类

（1）直接测量法

直接测量法是通过将锂电池进行充放电测试，测量到与 SOH 直接相关的老化参数，然后通过公式计算得到锂电池 SOH。直接测量法主要包括阻抗测量法和库仑计数法。文献[20]对测量的电化学阻抗谱（Electrochemical Impedance Spectroscopy, EIS）进行拟合，得到等效电路模型参数，然后通过模型参数中内阻与 SOH 之间的定义关系，计算得到锂电池 SOH。文献[21]首先从基于荷电状态（State of Charge, SOC）的差分电压曲线中识别出两个 SOC 特征点，然后将两个特征点的平均 SOC 以及相对应的时间直接代入公式，从而计算得到锂电池 SOH。直接测量法得到的锂电池 SOH 精度较高，但是该方法对实验仪器的要求很高且需耗费大量的时间，难以在锂电池实际的应用场景中使用。

（2）基于模型的方法

基于模型的方法需要对锂电池内部的退化机理进行深入研究，建立符合锂电池退化的物理模型，所建物理模型的准确性将直接影响到 SOH 的预测精度。常见的模型主要包括经验模型、等效电路模型和电化学模型等。

经验模型是通过将锂电池历史老化数据进行分析，利用不同的公式拟合出 SOH 的老化趋势，从而建立锂电池的经验退化模型。文献[22]通过研究不同放电深度下的放电量差异建立了一个包含放电速率、温度以及时间的经验模型，实验结果表明该模型能够在宽泛的循环条件下为锂电池 SOH 的衰减提供准确预测。文献[23]通过分析锂电池的老化机理，建立了一种单指数经验模型，并与粒子滤波（Particle Filter, PF）算法结合预测锂电池 SOH。文献[24]利用历

史容量老化数据建立锂电池老化的双指数模型，并采用改进蝴蝶算法优化的 PF 算法对模型参数进行更新，实现了 SOH 的准确预测。

等效电路模型是利用等效电源、电容以及电阻等相关电路元器件组合而成的模型，用以反映锂电池的外部电气特性，而不需要考虑电池内部复杂的化学反应机理。文献[25]基于二阶 RC 等效电路模型，提出了一种双扩展卡尔曼滤波算法，该算法通过估计欧姆内阻和 SOC 的变化，实现了 SOH 的准确估计。文献[26]提出了一种双自适应扩展粒子滤波算法，并结合分数阶模型实现了 SOC 与 SOH 的联合估计。实验结果表明，该算法既提高了估计精度，又降低了模型计算量。文献[27]在考虑温度和 SOC 影响的基础上，将 EIS 与等效阻抗模型进行拟合，然后利用模型参数中电荷转移电阻的大小，实现了 SOH 的在线预测。文献[28]采用遗传算法（Genetic Algorithm, GA）实时辨识二阶 RC 等效电路模型的参数，然后利用模型参数中的扩散电容在线预测锂电池 SOH。

电化学模型是基于大量的偏微分方程建立的，其能够准确描述锂电池内部的电化学特性。文献[29]采用 GA 算法辨识电化学模型中的模型参数，然后利用其中 5 个模型参数实现了锂电池 SOH 的准确预测。文献[30]在建立伪二维电化学模型的基础上，首先通过拆解电池测量其结构参数，然后利用优化算法辨识电化学模型中不可测量的模型参数，最后基于测量的参数和辨识的参数来预测锂电池 SOH。文献[31]建立了一个单粒子模型，通过将该模型中的偏微分方程简化为常微分方程，使得模型计算量显著降低。实验结果表明，该模型在实际应用中不仅能够实现 SOH 的快速预测，而且还具有较高的预测精度。基于模型的方法极易受到采集噪声和模型复杂度的不确定性影响，从而导致模型的预测精度较低、鲁棒性和泛化性较差。

（3）基于数据驱动的方法

基于数据驱动的方法预测锂电池 SOH 时，不需要深入研究电池内部的老化机制，只需从历史运行数据中提取出能够反映 SOH 的健康特征，然后通过构建数据驱动模型建立健康特征与 SOH 之间的映射关系，从而实现 SOH 的预测。常见的数据驱动模型有神经网络、高斯过程回归（Gaussian Process Regression, GPR）、支持向量回归（Support Vector Regression, SVR）以及相关向量机（Relevance Vector Machine, RVM）等。

神经网络是一种模拟人类神经元搭建的非线性模型，其能够很好的描述输入输出之间的非线性关系，但是存在着模型计算量大以及收敛速度慢等问题。文献[32]通过测量 EIS 中的最小阻抗，然后利用人工神经网络，建立最小阻抗与 SOH 之间的映射关系，该方法为 SOH 的准确预测提供一种新思路。文献[33]首先从充电过程中提取与 SOH 具有较强相关性的 5 个健康特征作为模型的输入，然后采用麻雀搜索算法优化的 Elman 神经网络对 SOH 进行预测。实验结果表明，相较于 Elman 神经网络和长短期记忆网络（Long Short-Term Memory, LSTM），该模型具有较高的预测精度和较强泛化性。

GPR 模型是一种基于贝叶斯框架的数据驱动模型，其可以准确捕捉数据间复杂的非线性关系，并且给出预测结果的置信区间，但是存在着模型计算量大和参数在线更新困难等问题。文献[34]提出了一种基于改进粒子群算法优化的 GPR 模型，以不同温度条件下自适应提取的健康特征作为输入，实现了 SOH 的在线预测。文献[35]对 GPR 模型的均值和协方差函数进行优化改进来预测锂电池 SOH。实验结果表明，改进后的 GPR 模型在预测精度和泛化能力方面均得到显著提升。

SVR 模型是一种建立在统计学基础上的数据驱动模型，其在处理小样本非线性问题上具有一定优势，但是 SVR 模型对于输入特征的要求较高且不适用于处理大样本问题。文献[36]充分提取了容量增量曲线中与 SOH 高度相关的健康特征，然后将健康特征作为 SVR 模型的输入来预测 SOH。文献[37]提出了一种基于改进蚁狮优化（Ant Lion Optimization, ALO）算法的 SVR 模型，并采用从锂电池充电过程中提取的 3 个健康特征作为模型的输入，进一步提高了 SOH 的预测精度。

RVM 模型是一种基于贝叶斯框架下的稀疏概率预测模型。相较于其它模型，RVM 模型具有计算时间快、泛化能力好等优点，被广泛应用于锂电池的 SOH 预测^[38]。文献[39]从放电过程中提取电压样本熵作为健康特征，并通过 RVM 模型实现了 SOH 的准确预测。文献[40]提出了一种基于蝙蝠算法优化的 RVM 模型预测 SOH，实验结果表明该模型相较于其它常见的数据驱动模型有着更高的预测精度。文献[41]采用多个核函数进行线性组合，建立了多核相关向量机（Multi-Kernel Relevance Vector Machine, MKRVM）模型，并利用果蝇优化算法对模型

参数进行优化,实验结果表明 MKRVM 模型的预测精度明显优于单一核函数的 RVM 模型。基于数据驱动的方法不需要研究锂电池内部的退化机理,就可以实现 SOH 的预测,但是单一的数据驱动模型难以达到较高的预测精度。

(4) 基于融合模型的方法

基于融合模型的方法是指结合不同的 SOH 预测方法,从而克服某单一预测方法的局限性,进一步提高 SOH 的预测精度。基于融合模型的方法主要分为两种,一种是模型和数据驱动方法的融合,另一种是多个数据驱动方法的融合。文献[42]提出了一种指数模型与 GPR 模型相融合的预测模型,首先采用 GPR 模型对初始循环的 SOH 进行预测,然后基于 GPR 模型的预测结果建立指数模型,并利用该指数模型预测后续循环的 SOH。当达到固定预测循环数之后,对指数模型的参数进行修正。实验结果表明,该融合模型在显著提升 SOH 预测精度的同时,进一步降低了模型计算量。文献[43]提出了一种卷积神经网络(Convolutional Neural Network, CNN)和 LSTM 相融合的 SOH 预测模型,并以充电过程中的电压数据作为模型的输入。实验结果表明,该模型既有 CNN 自动提取数据特征的优点,又具有 LSTM 处理序列数据的特长,有效提升了 SOH 的预测精度。文献[44]利用经验模态分解将锂电池的退化曲线分解为 3 个本征模态分量和 1 个残差分量,然后采用自回归模型和 Elman 神经网络分别对本征模态分量和残差分量进行预测,最后将各分量的预测结果进行叠加,得到了更为准确的 SOH 预测值。

随着锂电池 SOH 融合预测方法的深入研究,在 SOH 的预测中引入误差补偿环节受到了广泛的认可。文献[45]和文献[46]均采用经验模型对 SOH 进行初步预测,然后以历史数据中提取的健康特征为输入变量,经验模型的拟合误差为输出变量,建立基于数据驱动的误差补偿模型,对经验模型的初步预测值进行误差校正。实验结果表明,该融合模型在一定程度上克服了经验模型精度不足和泛化性较弱的问题。文献[47]采用 ELM 模型预测锂电池 SOH,然后通过灰色模型预测误差的累积趋势,对 ELM 模型的预测结果进行补偿,实验结果表明该方法显著提升了 SOH 的预测精度。基于融合模型的方法能够很好地集成不同预测方法的优点,有着较高的预测精度和较强的鲁棒性。

1.3 论文主要内容与章节安排

本文以锂电池为研究对象，在分析其工作原理和老化因素的基础上，主要针对锂电池健康特征的提取和 SOH 预测方法进行研究。论文总体框架结构如图 1-2 所示，各章的研究内容如下：




图 1-2 论文总体框架结构

第 1 章，绪论。首先介绍了课题研究背景及意义。然后，归纳总结了现阶段国内外学者关于 SOH 预测方法的主要研究成果。最后，对本文的研究内容和主要章节做了简要说明。

第 2 章，锂电池老化因素分析及数据来源。在本章中，首先介绍了锂电池的基本结构、工作原理以及老化的影响因素。然后，搭建了锂电池老化特性测

试平台，并开展相应的实验，获取了锂电池老化的相关测试数据。最后，介绍了马里兰大学高级生命周期工程中心（Center for Advanced Life Cycle Engineering, CALCE）公开数据集的具体信息，为后续章节提取健康特征和 SOH 预测提供数据支持。

第 3 章，锂电池健康特征的提取及相关性验证。考虑到锂电池放电过程的随机性较强，因此从相对规律的充电片段中提取能够反映 SOH 的健康特征。然后，通过健康特征与 SOH 之间的散点图定性分析二者之间的相关性。最后，采用 Pearson 相关系数和 Spearman 相关系数从不同方面定量评估健康特征与 SOH 之间的相关性，为下文 SOH 的准确预测奠定基础。

第 4 章，基于 ALO-MKRVM 模型的锂电池 SOH 预测。首先介绍了 BP 神经网络、SVR 和 RVM 模型的基本原理。然后，针对单一核函数的 RVM 模型预测精度不佳以及 MKRVM 模型中参数难以确定的问题，采用 ALO 算法对相关参数进行优化，建立了 ALO-MKRVM 模型。最后，利用 CALCE 数据集和实验室测试数据开展了实验验证，通过对比分析证明了 ALO-MKRVM 模型的有效性和准确性。

第 5 章，基于融合数据驱动方法的锂电池 SOH 预测。在 ALO-MKRVM 模型的基础上，为了能够准确预测锂电池老化过程中的容量再生现象，进一步提高 SOH 的预测精度，提出了一种基于融合数据驱动方法的 SOH 预测模型。该模型将 ALO-MKRVM 模型作为初始预测模型，并采用蚁狮优化的极限学习机（Ant Lion Optimization and Extreme Learning Machine, ALO-ELM）模型建立 SOH 误差补偿模型，通过 ALO-ELM 模型的输出对 SOH 初始预测值进行补偿，从而建立基于 ALO-MKRVM-ELM 的锂电池 SOH 融合预测模型。最后，利用 CALCE 数据集和实验室测试数据对该融合模型的有效性、先进性以及鲁棒性进行验证分析。

第 6 章，总结与展望。总结归纳了全文的研究工作和研究成果，并对下一步可能开展的研究方向进行展望，为后续的工作提供参考和借鉴。

第 2 章 锂电池老化因素分析及数据来源

2.1 引言

在实际应用中，锂电池长时间进行充放电循环会造成 SOH 的不可逆衰减，从而影响锂电池的安全稳定运行。因此，准确预测锂电池 SOH 具有重要的工程实践意义。对于 SOH 预测的研究，需要从锂电池内部的结构组成和工作原理出发，研究锂电池老化的内部因素和外部影响因素，从本质上分析 SOH 衰减的原因。因此，本章在分析锂电池内部结构和工作原理的基础上，首先对锂电池的老化因素进行剖析。然后，搭建了锂电池测试平台，并开展循环老化实验，获取了锂电池老化的相关测试数据。最后，介绍了 CALCE 数据集的具体信息，为下文提取健康特征以及准确预测 SOH 提供数据支撑。

2.2 锂电池基本结构和工作原理

锂电池主要由正极、负极、隔膜以及电解液四部分组成^[48-49]。其中，锂电池正极通常是由含锂的化合物组成，化学稳定性较好且一般不会与电解液发生反应。锂电池负极一般由碳材料组成，负极材料的不同将直接影响到锂离子脱嵌和嵌入的能力。隔膜是位于锂电池正负极材料之间的薄膜，其主要作用是防止正负极直接接触而导致锂电池内部短路。在充放电过程中，隔膜只允许锂离子通过，从而保证了电池电流的正常流动，有效降低了短路的风险。电解液是位于内部隔膜两侧的有机溶液，其是连接电池正负极的介质，起到传输锂离子的作用。锂电池的内部结构如图 2-1 所示。




图 2-1 锂电池的内部结构图

图 2-2 为锂电池的工作原理图，从图中可以看出锂电池的工作原理是内部的锂离子通过电解液在正负极之间持续移动，从而实现能量的转移与存储。在充电过程中，锂离子不断地从正极脱嵌，穿过电池内部的隔膜，到达并嵌入到负极中。与此同时，为了保持电池内部的电荷平衡，相同数量的电子则通过外部电路从正极出发迁移到负极。放电过程中锂离子与电子的运动方向与充电过程中的运动方向完全相反。在放电过程中，锂离子从负极脱嵌，穿过隔膜到达正极，电子则从负极出发经过外部电路转移到正极。整个充放电过程中在正负极之间转移的锂离子越多，说明锂电池的充放电容量越高。





图 2-2 锂电池的工作原理图


本章以磷酸铁锂（ LiFePO_4 ）电池为例，分析锂电池充放电时的内部化学反应方程式。锂电池正极的化学反应方程式如下所示：



锂电池负极的化学反应方程式如下所示：



锂电池内部的总化学反应方程式如下所示：



由上述分析可知，锂电池充电和放电的过程是完全可逆的，其本质是锂离子和电子分别利用电解液和外部电路实现转移，从而保持锂电池内部的电荷守恒。

2.3 锂电池老化因素分析

2.3.1 内部因素

在锂电池内部中，老化的主要原因是长时间使用后，锂电池的内部结构和材料发生了改变，主要体现在锂离子的损失、SEI膜的生长、电极材料的损耗以及隔膜材料的老化等^[50-51]。

（1）锂离子的损失

锂电池在长期使用中，大量的锂离子可能会在负极附近发生还原反应，导致金属锂析出，这些析出的金属锂会附着在锂电池电极的表面。锂离子的损失会使得锂电池容量下降，老化程度加深。

（2）SEI膜的生成

在锂电池充放电过程中，电解液与负极材料之间会在所难免的发生化学反应，进而在锂电池的负极表面形成一层薄膜即 SEI 膜。SEI 膜的生成不仅消耗了部分锂离子，而且减小了电解液与电极材料之间的接触面积。因此会对锂电池正负极材料的性能产生影响，导致容量不可避免地发生衰减，并且 SEI 膜的生成还会降低锂电池的充放电效率。

（3）电极材料的损耗

锂电池的容量与正负极材料脱嵌和嵌入锂离子的能力紧密相关，这一能力的强弱直接决定了电池储存和释放电量的大小。锂电池经过长期充放电循环之后，电极材料不可避免地产生损耗，进而减弱了正负极材料脱嵌和嵌入锂离子的能力，从而使得锂电池容量逐渐下降。电极材料的损耗是多种因素耦合造成的，例如 SEI 膜的生成、电极材料与电解液发生副反应等。

（4）隔膜材料的老化

锂电池长期充放电以后，一方面锂电池中间的隔膜材料会逐渐收缩，导致电池内阻上升，容量下降；另一方面，电解液与电极材料长时间发生副反应，产生大量的副反应生成物会堵塞隔膜的过孔，影响充放电过程中的锂离子传输效率，进而导致锂电池容量下降。

（5）自放电现象

在静置时，锂电池内部的电解液与电极材料之间会存在着微弱的电流，即

锂电池的自放电现象，长期存在这种情况，会导致锂电池容量下降。同时，锂电池在静置时的温度与湿度过于极端会加剧自放电现象的发生。

2.3.2 外部影响因素

影响锂电池性能老化的因素多种多样，除了锂电池内部结构和材料发生变化之外，在使用时的工作模式和温度的不同也会对其老化造成一定程度的影响。外部影响因素主要包括锂电池使用时的充放电倍率、充放电截止电压以及环境温度等^[52]。

（1）充放电倍率

充放电倍率的大小直接影响着锂电池的充放电时间，虽然高倍率充电能够快速将锂电池电量充满，但是其内部温度会快速升高，SEI膜加速生长，内阻增大，使得锂电池加速老化。当采用高倍率放电时，与低倍率放电相比锂电池的正极结构会发生明显变化，负极 SEI 膜明显增厚以及锂离子数量明显减小，从而使得锂电池的老化程度加深。

（2）充放电截止电压

锂电池充电截止电压过高以及放电截止电压过低都会加剧锂电池的性能老化。当充电截止电压过高时，会引起锂电池内部电阻变大，副反应增加，负极 SEI膜明显增厚。当放电截止电压过低时，也会引起锂电池内部副反应增加，同时在负极上会出现析锂现象，导致电池内阻增加，电池容量下降。

（3）环境温度

锂电池使用时的环境温度过高过低都会影响到实际的放电容量。当锂电池处于高温环境下，内部副反应加剧，因此会损耗内部的电解液、隔膜以及电极材料，进而影响锂电池的老化程度。当锂电池处于低温环境下，内部的锂离子活性以及电极之间的反应速率会降低，从而导致锂电池容量下降。因此，将锂电池控制在合适的温度下工作，能够有效减缓其性能老化的进程。

2.4 实验室测试数据

2.4.1 测试平台

实验室搭建的锂电池测试平台如图 2-3 所示，其主要由 3 部分组成，分别为

上位机、电池测试系统和高低温试验箱。




图 2-3 实验室搭建的锂电池测试平台

其中，电池测试系统采用深圳亚科源公司生产的 5V-60A-8 通道的充放电测试系统。该测试系统支持 8 个通道单独操作，单通道的电压测量范围为 0-5V，电流测量范围为 0-60A，最大功率可达 300W。电压与电流的测量精度分别为 2.5mV 和 30mA，并且该系统具备循环嵌套功能，最大支持 3 层嵌套。表 2-1 为 5V-60A-8 通道电池测试系统的详细技术参数。

表 2-1 5V-60A-8 通道电池测试系统的技术参数

指标项目	技术参数
电压/电流	充放电电压范围 0-5V
	充放电电流范围 0-60A
	测量精度/稳定度 $\pm 0.05\%FS/\pm 0.05\%FS$
	采样频率 100HZ
工作模式	恒流充放电、恒压充放电、恒功率充放电、脉冲工步、工况模拟、DCIR 直流内阻测试以及循环测试等

高低温试验箱采用深圳亚科源公司生产的 YKYTECH-408L 型号产品，该设备可将温度控制在-10℃到 150℃，温度波动度在 $\pm 0.3^{\circ}C$ 。高低温试验箱的详细技术参数如表 2-2 所示。

表 2-2 高低温试验箱的技术参数

指标项目	参数	指标项目	参数
型号	YKYTECH-408L	温度分辨率	0.1℃
尺寸	1050*1650*1950(mm)	温度均匀度	≤±2℃
电源	AC380V/50Hz	温度波动度	≤±0.3℃
额定功率	8.5KW	温度范围	-10℃-150℃

2.4.2 数据测试步骤

通过实验室搭建的锂电池测试平台开展循环老化实验，以获取锂电池老化的相关测试数据。循环老化实验采用国内某厂家生产的三元锂电池，额定容量为 40Ah，该电池的规格参数如表 2-3 所示。

表 2-3 40Ah 三元锂电池的规格参数

指标项目	参数
额定容量	40Ah
标称电压	3.7V
工作温度	-20℃-55℃
充电截止电压	4.2V
放电截止电压	2.7V
重量	400g

循环老化实验中，共设计了 3 块锂电池在相同的条件下进行充放电循环。同时，为加速锂电池老化进程，将高低温试验箱的环境温度设为 45℃。3 块锂电池分别命名为电池 S1、电池 S2 以及电池 S3，并且在循环老化实验中分别采集到 1000、1000 和 893 组数据。循环老化实验流程图如图 2-4 所示，具体步骤如下：

步骤 1：将锂电池放置于高低温试验箱中，并将环境温度设置为 45℃。

步骤 2：采用 1C 的放电倍率对锂电池进行恒流（Constant Current，CC）放电，直至电压降至 2.7V。

步骤 3：将锂电池静置半小时。

步骤 4：以 1C 的充电倍率进行 CC 充电，当电压达到 4.2V 时，充电模式转

为恒压（Constant Voltage, CV）充电，当充电电流降为 2A 时，充电结束。

步骤 5：充电完毕后，将锂电池静置半小时。

步骤 6：采用 1C 的放电倍率对锂电池进行 CC 放电，当锂电池电压降至 2.7V 时，放电结束。

步骤 7：重复步骤 3~步骤 6，直至锂电池的放电容量降低至额定容量的 80% 以下。




图 2-4 实验室循环老化实验流程图

实验室测试数据中单次循环的电压电流曲线以及容量老化曲线分别如图 2-5 和图 2-6 所示。




图 2-5 实验室测试数据中单次循环的电压电流曲线




图 2-6 实验室测试数据的容量老化曲线

2.5 CALCE 数据集

为更好的验证模型的预测性能，除了采用实验室测试数据外，还采用公开的 CALCE 数据集。在 CALCE 数据集中采用 CS2-35、CS2-36、CS2-37 和 CS2-38 锂电池的循环老化数据，其中 4 块电池的额定容量均为 1.1Ah^[53]。本文选用 4 块电池的前 800 组循环老化数据，验证模型的预测性能。CALCE 数据集的实验步骤与实验室测试数据的实验步骤类似，具体为：在 24℃环境下，首先以 0.5C（0.55A）的充电速率进行 CC 充电，当电压升至 4.2V 时，进入 CV 模式，当充电电流小于 50mA 时，充电结束。然后进行 CC 放电，放电电流大小为 1C（1.1A），电压降至 2.7V 时，放电结束。CALCE 数据集的详细信息如表 2-4 所示。

表 2-4 CALCE 数据集的详细信息

序号	温度	充电电流	充电截止电压	充电截止电流	放电电流	放电截止电压
CS2-35	24℃	0.55A	4.2V	50mA	1.1A	2.7V
CS2-36	24℃	0.55A	4.2V	50mA	1.1A	2.7V
CS2-37	24℃	0.55A	4.2V	50mA	1.1A	2.7V
CS2-38	24℃	0.55A	4.2V	50mA	1.1A	2.7V

CALCE 数据集中单次循环的电压电流曲线以及容量老化曲线分别如图 2-7 和图 2-8 所示。




图 2-7 CALCE 数据集中单次循环的电压电流曲线




图 2-8 CALCE 数据集的容量老化曲线

2.6 本章小结

本章在阐述锂电池内部结构和工作原理的基础上，首先从内部因素和外部影响因素两个方面对锂电池的老化原因进行了研究分析。然后，搭建电池测试平台，开展了锂电池充放电循环老化实验，并记录了相关测试数据。最后，介绍了公开的 CALCE 数据集，为本文后续提取健康特征和 SOH 预测提供了数据支持。


第 3 章 锂电池健康特征的提取及相关性验证

3.1 引言


锂电池 SOH 可以直接通过电池容量或者内阻计算得到，但在实际应用中，BMS 难以直接获取相关数据。因此，只能从 BMS 采集到的电压、电流以及温度等数据中提取出能够间接表征锂电池 SOH 的健康特征，然后利用相应的算法对锂电池 SOH 进行预测。健康特征与锂电池 SOH 的相关程度将直接影响到预测的精度，然而由于电池的放电工况具有很强的随机性^[54-55]。因此，本章将从相对规律的充电片段中提取健康特征，并通过散点图定性分析健康特征与锂电池 SOH 之间的相关性。最后，采用 Pearson 和 Spearman 相关系数定量评估健康特征与 SOH 之间的相关程度，指导提取有效的健康特征，为后续 SOH 的准确预测奠定基础。

3.2 健康特征提取


锂电池的放电工况随机性较强，从中提取的健康特征不具有普适性^[56-57]。而锂电池经历一定的循环后，其内部电解液、电极材料和隔膜均会出现一定程度的老化，那么锂电池的充电时间必然随着锂电池的老化而减少。考虑到锂电池在实际应用中一般不会满充满放，因此考虑在电压范围为 3.7V~4.1V 的充电片段中提取出与锂电池 SOH 强相关性的健康特征。图 3-1 和图 3-2 分别为 CALCE 数据集和实验室测试数据在不同循环次数下的锂电池 CC 充电电压曲线。




(a) CS2-35 电池



(b) CS2-36 电池




(c) CS2-37 电池




(d) CS2-38 电池


图 3-1 CALCE 数据集在不同循环次数下的 CC 充电电压曲线



(a) S1 电池



(b) S2 电池



(c) S3 电池

图 3-2 实验室测试数据在不同循环次数下的 CC 充电电压曲线

通过图 3-1 和图 3-2 可以看出, 随着循环次数的增加, 锂电池电压从 3.7V 上升到 4.1V 的等压升充电时间总体呈现逐渐减少的趋势, 并且 CC 充电电压曲线逐渐左移。这是因为随着锂电池长时间的使用, 内阻不断增大, 而电压可以反应出内阻的变化。因此, 提取电压范围为 3.7V~4.1V 的等压升充电时间作为健

康特征，以表征 SOH 的退化趋势，记为 F1。

在实际的工程应用中，通常只能监测到锂电池的电压、电流以及表面温度等外部参数，难以检测到锂电池内部的电化学反应。而锂电池的容量增量曲线可以有效反映出锂电池内部的锂离子损失，因此被认为是反映锂电池老化的有效工具，并且利用容量增量曲线研究分析电池的老化机理，不需要对电池进行拆解破坏，就可以获得电压电流曲线中无法直观显示的电化学信息^[58]。容量增量曲线是通过数学手段将锂电池充放电过程中的电压和容量数据进行微分处理得到的，其曲线的变化趋势能够反映电池老化对内部电化学反应的影响。容量增量曲线的计算公式，如式（3-1）所示：

$$\frac{dQ}{dV} \approx \frac{\Delta Q}{\Delta V} = I \frac{dt}{dV} \quad (3-1)$$

式中， V 为端电压； Q 为充电容量； t 为充电时间； I 为充电电流。

由于采样噪声的存在，使得容量增量曲线的变化趋势较为剧烈。因此，需要对容量增量曲线进行滤波处理，以获得更加平稳的数据。针对这一问题，本章将采用局部加权散点平滑（Locally Weighted Scatterplot Smoothing, LOWESS）的方法，对原始容量增量曲线进行滤波处理，以提高原始数据的准确性和可靠性^[59]。LOWESS 滤波是一种对数据进行滤波的有效方法，其对异常值具有较强的鲁棒性，并且可以有效消除异常值对拟合结果的干扰。LOWESS 滤波的具体原理是以一个点为中心，在指定窗口长度内对周围的数据点进行迭代加权最小二乘回归。每个平滑值都是由指定窗口长度内的相邻数据点决定的，较大的窗口长度会导致历史数据过多，减小了最新信息对平滑值的影响。LOWESS 滤波可以通过一定比例自适应地获取窗口长度的大小，因此 LOWESS 滤波能够在保持平滑效果的同时，更好地适应数据的局部变化，不仅可以减少历史数据对最新信息的影响，还能提高平滑效果的准确性和实时性。

图 3-3 为 CALCE 数据集和实验室测试数据滤波前后的容量增量曲线，如图所示，滤波后的容量增量曲线与原始容量增量曲线的趋势基本保持一致，且滤波后的曲线更加光滑，数据特征更为明显。




图 3-3 滤波处理前后的容量增量曲线

图 3-4 和图 3-5 分别为 CALCE 数据集和实验室测试数据在不同循环次数下的容量增量曲线。通过图 3-4 和图 3-5 可以看出，随着循环次数的增加，CALCE 数据集和实验室测试数据的容量增量曲线峰值均呈现出明显的下降趋势，并且考虑到容量增量曲线的峰值能够有效反映出电池正负极材料的衰变。因此，提取容量增量曲线的峰值作为健康特征反映锂电池的老化程度，记为 F2。




图 3-4 CALCE 数据集在不同循环次数下的容量增量曲线




图 3-5 实验室测试数据在不同循环次数下的容量增量曲线

同时，通过图 3-4 和图 3-5 可以看出，随着循环次数的增加，CALCE 数据集和实验室测试数据的容量增量曲线在电压范围 3.7V~4.1V 之间的峰面积有着显著减小的趋势。因此，提取容量增量曲线在电压范围 3.7V~4.1V 之间的峰面积作为健康特征反映锂电池的老化程度，记为 F3。

在实际使用中，随着循环次数的增加，锂电池容量会出现不可避免的衰减现象。通过图 2-6 和图 2-8 可以看出，在实验室测试数据和 CALCE 数据集上，随着循环次数的增加，锂电池容量均呈现出非线性的下降趋势，说明了循环次数与 SOH 之间存在着明显的负相关特性。这是因为锂电池经过多次充放电循环后，内部极化现象越来越明显，隔膜、电解液以及正负极材料均出现不同程度的损耗，从而导致电池内阻变大，电池容量下降。在多输入单输出的数据驱动模型中，输入的特征向量越多，数据驱动模型的预测性能越好。因此，将循环次数也作为健康特征，以提高 SOH 的预测精度，记为 F4。

3.3 相关性验证

3.3.1 定性评估

为了更直观地显示提取的健康特征 F1~F4 与 SOH 之间的相关性，分别做出健康特征 F1~F4 与 SOH 之间的散点图。图 3-6 为 CALCE 数据集和实验室测试数据提取的健康特征 F1 与 SOH 之间的散点图，从图中可以看出，SOH 随着等压升充电时间的增加而增加，二者呈现出明显的正相关性，说明了提取的健康特征 F1 可以有效反映锂电池 SOH 的退化趋势。




图 3-6 健康特征 F1 与 SOH 的关系




图 3-7 健康特征 F2 与 SOH 的关系

图 3-7 为 CALCE 数据集和实验室测试数据提取的健康特征 F2 与 SOH 之间的散点图，从图中可以看出，SOH 随着容量增量曲线峰值的增加而增加，说明了 SOH 与容量增量曲线的峰值存在着一定的正相关性，并且实验室测试数据的正相关性明显强于 CALCE 数据集的正相关性。因此，从图 3-7 可知，CALCE 数

据集和实验室测试数据上提取的健康特征 F2 能够很好地反映 SOH 的退化趋势。

图 3-8 为 CALCE 数据集和实验室测试数据中提取的健康特征 F3 与 SOH 之间的散点图，从图中可以明显观察出，容量增量曲线的峰面积与 SOH 之间也呈现出明显的正比例关系，说明了容量增量曲线的峰面积也能够很好地反映锂电池的老化程度。




图 3-8 健康特征 F3 与 SOH 的关系

图 3-9 为 CALCE 数据集和实验室测试数据中提取的健康特征 F4 与 SOH 之间的散点图，从图中可以看出，随着循环次数的增加，SOH 出现明显的下降趋势，说明了循环次数与 SOH 之间存在着明显的负相关性。




图 3-9 健康特征 F4 与 SOH 的关系

综上，通过健康特征 F1~F4 与 SOH 之间的散点图定性分析可知，健康特征 F1~F4 与 SOH 之间均存在着明显的线性关系，一定程度上说明了健康特征 F1~F4 能够很好地反映锂电池 SOH 的退化趋势。

3.3.2 定量评估

虽然健康特征 F1~F4 在各自的散点图上都能够直观地看出与 SOH 之间具有一定的正相关性或负相关性，但是未通过定量评估的方法具体衡量健康特征 F1~F4 与 SOH 之间的相关程度。因此，为防止某些健康特征与 SOH 之间的相关性较低，让其参与锂电池 SOH 的预测中不仅会加大模型计算量，使得训练时间和预测时间变长，而且还会让 SOH 预测精度降低。所以本章将通过 Pearson 和 Spearman 相关系数定量评估健康特征 F1~F4 与 SOH 之间的相关程度，防止出现冗余健康特征。Pearson 相关系数主要应用于连续型数据分析，需假设两个变量分别服从正态分布且标准差均不为零，然后通过计算两个变量之间协方差与标准差的比值，从而衡量两个变量之间的线性相关程度，但是 Pearson 相关系数对于异常数据比较敏感。Pearson 相关系数的计算公式，如式（3-2）所示：

$$P_{xy} = \frac{Cov(x, y)}{\sigma_x \sigma_y} \quad (3-2)$$

式中， $Cov(x, y)$ 为变量 x 和 y 的协方差； σ_x 和 σ_y 分别为变量 x 和 y 的标准差。

Spearman 相关系数是将两个变量的数据按大小排序，然后计算排序后数据的相关性。相对于 Pearson 相关系数，Spearman 相关系数不仅可以捕捉到变量之间的线性相关性，还可以捕捉到变量之间的单调关系。因此，无论是连续型数据还是离散型数据，Spearman 相关系数均能有效衡量二者的相关性。Spearman 相关系数的计算公式，如式（3-3）所示：

$$S_{xy} = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2 - 1)} \quad (3-3)$$

式中， d 为两个变量的秩差； N 为两个变量的数据长度。

由上述可知，Pearson 和 Spearman 相关系数能从不同角度去评估两个变量之间的相关程度，并且二者的取值范围均为 $[-1, 1]$ 。如果相关系数为正值，则表明两变量存在着正相关性；如果相关系数为负值，则表明两变量存在着负相关性。如果相关系数的绝对值越接近于 1，则说明两变量的相关性越强；如果相关系数的绝对值接近于 0，则说明两变量的相关性越弱。一般相关系数的绝对值大于 0.6 就认为两变量存在着较强的相关性。表 3-1 和表 3-2 分别为 Pearson 和

Spearman 相关性分析结果。

表 3-1 Pearson 相关性分析结果

电池	F1	F2	F3	F4
CS2-35	0.989	0.926	0.967	-0.902
CS2-36	0.990	0.938	0.959	-0.934
CS2-37	0.974	0.944	0.980	-0.950
CS2-38	0.958	0.935	0.968	-0.946
S1	0.902	0.991	0.904	-0.990
S2	0.861	0.997	0.870	-0.991
S3	0.934	0.993	0.956	-0.987

表 3-2 Spearman 相关性分析结果

电池	F1	F2	F3	F4
CS2-35	0.978	0.962	0.956	-0.980
CS2-36	0.991	0.959	0.985	-0.996
CS2-37	0.981	0.966	0.980	-0.992
CS2-38	0.954	0.984	0.959	-0.991
S1	0.747	0.997	0.783	-0.999
S2	0.733	0.998	0.736	-0.994
S3	0.848	0.996	0.857	-0.998

根据表 3-1 和表 3-2 的相关性分析结果可知：在实验室测试数据中，健康特征 F1~F4 与 SOH 的 Pearson 和 Spearman 相关系数的绝对值均在 0.73 以上；并且在 CALCE 数据集中，Pearson 和 Spearman 相关系数的绝对值均在 0.9 以上。因此，相关性分析结果充分表明健康特征 F1~F4 与 SOH 之间存在着较强的相关性，可用于 SOH 的准确预测。

3.4 本章小结

本章主要开展了锂电池健康特征的提取及相关性验证工作。通过散点图定性分析，以及 Pearson 和 Spearman 相关系数定量评估，确定了从电池运行状态相对规律的充电片段中提取等压升充电时间、容量增量曲线的峰值、容量增量曲线的峰面积以及循环次数 4 个健康特征，为后续章节的 SOH 预测算法研究提供理论依据。

第 4 章 基于 ALO-MKRVM 的锂电池 SOH 预测

4.1 引言

准确预测锂电池 SOH，不仅要求提取的健康特征与 SOH 之间具有较强相关性，而且选择合适的算法也尤为关键。RVM 模型由于其性能优势已广泛应用于锂电池的 SOH 预测，但是单一核函数的 RVM 模型在长期预测中会出现精度不佳以及适用性不高等问题。因此，本章将选用 MKRVM 模型，并采用 ALO 算法对其模型参数进行优化，从而建立基于 ALO-MKRVM 的锂电池 SOH 预测模型。最后，利用 CALCE 数据集和实验室测试数据进行实验验证，并通过 3 种评价指标对比分析 ALO-MKRVM 模型相较于 BP 神经网络、SVR、RVM 以及 MKRVM 模型的性能优势，为下一步融合模型的研究奠定基础。

4.2 典型预测模型

4.2.1 BP 神经网络

BP 神经网络是一种多层前馈神经网络，其主要由输入层、隐藏层和输出层构成，网络结构如图 4-1 所示。




图 4-1 BP 神经网络的模型结构

BP 神经网络的基本原理是通过训练使输入量经过网络各层处理，最终在输

出层产生预测输出。当预测误差超过设定阈值时，网络会启动误差反向传播机制。在这一阶段，网络会调整各层之间的连接权重和偏置参数，直至预测误差降低至期望范围内，从而完成 BP 神经网络的训练。

在 BP 神经网络中，隐藏层的神经元个数可由式（4-1）确定：

$$t = \sqrt{p+l} + \alpha \quad (4-1)$$

式中， p 和 l 分别为输出层和输入层的神经元个数； α 为 1~10 之间的整数。

在本章中，输出层和输入层的神经元个数分别为 1 个和 4 个，所以隐藏层的神经元个数设为 10 个，并且隐藏层和输出层的激励函数分别选用 Tansig 函数和 Purelin 函数，具体表达式如下所示：

$$f_{Tansig}(x) = \frac{2}{1+e^{-2x}} - 1 \quad (4-2)$$

$$f_{Purelin}(x) = x \quad (4-3)$$

4.2.2 支持向量回归

SVR 模型是针对回归预测问题提出的，其主要原理与 SVM 模型类似。图 4-2 为 SVR 模型的原理图。




图 4-2 SVR 模型的原理图

SVR 模型的基本原理是将所有样本点与所求超平面之间的距离和转化为最小值问题，从而找到最优超平面建立回归预测模型。SVR 模型与其他传统线性回归模型的区别是，其他传统线性回归模型在训练时是计算预测值与真实值之

间的偏离程度，相应的损失误差为零时，表示训练完成。SVR 模型则能够容忍一定范围内的误差，当预测值与真实值之间的误差在允许范围之内，即可认为模型训练完成^[60]。

假设 SVR 模型的训练集为 $\{(x_i, y_i) | i=1, 2, \dots, n\}$ ，其中 x_i 和 y_i 分别代表第 i 次训练时的输入量与输出量， n 表示训练集样本的数量。则 SVR 模型的回归函数如下所示：

$$f(x) = w \cdot \varphi(x) + b \quad (4-4)$$

式中， w 为权值； $\varphi(x)$ 为非线性映射函数； b 为截距。

由于 SVR 模型允许一定范围内的偏差，则 w 和 b 可通过目标函数进行求解，如下所示：

$$\min_{w,b} \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n L(f(x_i) - y_i) \quad (4-5)$$

式中， c 为惩罚因子； $L(f(x_i) - y_i)$ 为损失函数。

通过引入松弛变量 $\{\xi_i\}_{i=1}^n$ 和 $\{\xi_i^*\}_{i=1}^n$ ，即可将式 (4-5) 转化为式 (4-6)，且式 (4-6) 的约束条件如式 (4-7) 所示：

$$\min R(w, b, \xi_i, \xi_i^*) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (4-6)$$

$$s.t. \begin{cases} y_i - w \cdot \varphi(x) - b \leq \varepsilon + \xi_i \\ w \cdot \varphi(x) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (4-7)$$

式中， c 为惩罚因子； ε 为允许的最大损失误差。

通过引入拉格朗日乘子将式 (4-6) 转化为求解对偶问题，如下所示：

$$\begin{aligned} \max R(a_i^*, a_i) = & -\frac{1}{2} \sum_{i,j}^n (a_i^* - a_i)(a_j^* - a_j) \varphi(x_i) \varphi(x_j) \\ & - \sum_i^n a_i (y_i + \varepsilon) + \sum_j^n a_j (y_j + \varepsilon) \end{aligned} \quad (4-8)$$

式中， a_i 和 a_i^* 为拉格朗日乘数，且式 (4-8) 的约束条件如下所示：

$$s.t. \begin{cases} \sum_i^n (a_i^* - a_i) = 0 \\ 0 \leq a_i, a_i^* \leq c \quad i=1, 2, \dots, n \end{cases} \quad (4-9)$$

在最小化拉格朗日函数后，即可得到 SVR 模型的回归函数，如下所示：

$$f(x) = \sum_i^n (a_i^* - a_i) K(x_i, x) + b \quad (4-10)$$

式中， $K(x_i, x) = \varphi(x_i)\varphi(x_j)$ 为 SVR 模型的核函数。

本章采用高斯核函数作为 SVR 模型的核函数，具体表达式如下所示：

$$K_{Gaussian}(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\sigma^2) \quad (4-11)$$

式中， σ 为高斯核函数的核参数。

4.2.3 相关向量机

RVM 是基于贝叶斯框架下的稀疏概率预测模型，首先在贝叶斯框架下进行训练，在设定先验参数后，通过不相关理论剔除一些不相关点，由此可以得到稀疏概率预测模型^[61]。

在 RVM 模型中，假定训练样本的输入为 $\{x_n\}_{n=1}^N$ ，输出为 $\{t_n\}_{n=1}^N$ ，其中 N 是样本总数，则输入与输出之间的关系如下所示：

$$t_n = y(x_n) + \varepsilon_n \quad (4-12)$$

式中， ε_n 是服从独立分布的高斯噪声，记为 $\varepsilon_n \sim N(0, \sigma^2)$ 。

回归函数 $y(x_n)$ 常由下式表示：

$$y(x|w) = \sum_{i=1}^N w_i k(x, x_i) + w_0 \quad (4-13)$$

式中， $k(x, x_i)$ 为核函数； w 为 $k(x, x_i)$ 对应的权重向量，且 $w = (w_1, w_2, \dots, w_N)^T$ ； w_0 为偏置参数。

若输出 t_n 服从独立分布，则训练样本的似然估计概率可以表示为：

$$p(t|w, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp(-\frac{\|t - \Phi w\|^2}{2\sigma^2}) \quad (4-14)$$

式中， Φ 为 $N \times (N+1)$ 的核函数矩阵，其定义如下：

$$\Phi = [\varphi(x_1), \varphi(x_2), \dots, \varphi(x_N)]^T \quad (4-15)$$

$$\varphi(x_i) = [1, k(x_i, x_1), k(x_i, x_2), \dots, k(x_i, x_N)] \quad (4-16)$$

为了避免求解过程中出现过度学习的情况，即过拟合现象，故将 w 定义为一个零均值的高斯先验分布，如下所示：

$$p(w|\alpha) = \prod_{i=0}^N N(w_i|0, \alpha_i^{-1}) \quad (4-17)$$

式中， $\alpha = (\alpha_0, \alpha_1, \dots, \alpha_N)^T$ 为 $N+1$ 维的超参数向量，超参数 α_i 和权重 w_i 均一一对应。

根据贝叶斯定理，可知其他所有未知参数的后验分布可以表示为：

$$p(w, \alpha, \sigma^2 | t) = p(w | t, \alpha, \sigma^2) p(\alpha, \sigma^2 | t) \quad (4-18)$$

根据式（4-14）和式（4-18），再结合贝叶斯定理，即可推导出 w 的后验分布，如下所示：

$$\begin{aligned} p(w | t, \alpha, \sigma^2) &= \frac{p(t | w, \sigma^2) p(w | \alpha)}{P(t | \alpha, \sigma^2)} \\ &= (2\pi)^{-\frac{N+1}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(w-u)^T |\Sigma|^{-1} (w-u)\right\} \end{aligned} \quad (4-19)$$

式中， Σ 和 u 分别为 w 后验分布的协方差和均值，定义如下：

$$\Sigma = (\sigma^{-2} \Phi^T \Phi + A)^{-1} \quad (4-20)$$

$$u = \sigma^{-2} \Sigma \Phi^T t \quad (4-21)$$

式中， A 为超参数 α_0 到 α_N 构成的对角矩阵。

此时，RVM 模型训练的目的转化为求解 $p(\alpha, \sigma^2 | t)$ 的最大化问题。由于 $p(\alpha, \sigma^2 | t) \propto p(t | \alpha, \sigma^2) p(\alpha) p(\sigma^2)$ ，如果使 $p(\alpha, \sigma^2 | t)$ 最大，则要求 $p(t | \alpha, \sigma^2)$ 最大。 $p(t | \alpha, \sigma^2)$ 的定义如下：

$$\begin{aligned} p(t | \alpha, \sigma^2) &= \int p(t | w, \sigma^2) p(w | \sigma) dw \\ &= (2\pi)^{-\frac{N}{2}} \left| \sigma^2 I + \Phi A^{-1} \Phi^T \right|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2} t^T (\sigma^2 I + \Phi A^{-1} \Phi^T)^{-1} t\right\} \end{aligned} \quad (4-22)$$

在式（4-22）中分别对超参数 α 和噪声方差 σ^2 求偏导且令偏导数为零，则可得：

$$\alpha_i^{new} = \frac{1 - \alpha_i \sum_{ii}}{u_i^2} \quad (4-23)$$

$$(\sigma^2)^{new} = \frac{\|t - \Phi u\|^2}{N - \sum_{i=0}^N (1 - \alpha_i \sum_{ii})} \quad (4-24)$$

式中， $\sum_{ii}$ 为后验协方差 Σ 的第 i 个对角线元素； u_i 为第 i 个后验权值的均值。

RVM 模型的训练过程就是不断迭代式 (4-23) 和式 (4-24) 求解 α_i^{new} 和 $(\sigma^2)^{new}$ 。当满足收敛条件时, 得到超参数 α 和噪声方差 σ^2 的最优值分别记为 α_{MP} 和 σ_{MP}^2 。

当设定 x_* 为一组新输入时, 则相对应的预测输出概率分布如下所示:

$$p(t_* | t, \alpha_{MP}, \sigma_{MP}^2) = N(t_* | y_*, \sigma_*^2) \quad (4-25)$$

式中, y_* 为预测输出值, σ_*^2 为方差, 分别定义如下:

$$y_* = u^T \varphi(x_*) \quad (4-26)$$

$$\sigma_*^2 = \sigma_{MP}^2 + \varphi(x_*)^T \Sigma \varphi(x_*) \quad (4-27)$$

本章采用单一核函数的 RVM 模型预测锂电池 SOH 时, 同样选择高斯核函数作为 RVM 模型的核函数。

4.3 ALO-MKRVM 模型的基本原理

4.3.1 蚁狮优化算法原理

ALO 算法是文献[62]在 2015 年提出的一种智能优化算法, 其灵感来源于自然界中蚁狮捕捉蚂蚁的行为。在 ALO 算法中, 采用随机游走策略模拟蚂蚁的行走, 表明了最优解是在全局范围内搜索得到。同时, 蚁狮利用陷阱捕捉蚂蚁, 当捕捉到蚂蚁后, 蚁狮重新制作陷阱, 等待下一个蚂蚁掉入陷阱。ALO 算法相对于其他智能优化算法, 如鲸鱼优化算法、粒子群优化算法以及灰狼优化算法等具有原理简单, 调节的参数较少和不会陷入局部最优等优势。ALO 算法的具体步骤如下:

(1) 蚂蚁的随机游走

采用随机游走策略模拟蚂蚁的随机游走, 其定义如下所示:

$$X(t) = [0, cumsum(2m(t_1) - 1), cumsum(2m(t_2) - 1), \dots, cumsum(2m(t_n) - 1)] \quad (4-28)$$

式中, $cumsum$ 为随机游走的累计和; n 为最大迭代次数; $m(t_n)$ 为随机游走函数, 其定义如下所示:

$$m(t) = \begin{cases} 1 & \text{if } rand > 0.5 \\ 0 & \text{if } rand \leq 0.5 \end{cases} \quad (4-29)$$

式中, $rand$ 为[0,1]内均匀分布的随机数。

同时, 为了保证蚂蚁在随机游走过程中始终保持在搜寻空间内, 故对式(4-28)中的蚂蚁位置进行归一化处理, 其定义如下所示:

$$X_i^t = \frac{(X_i^t - a_i) \times (d_i - c_i^t)}{(d_i^t - a_i)} + c_i^t \quad (4-30)$$

式中, d_i^t 和 c_i^t 分别为第 i 个变量在第 t 次迭代时的最大值和最小值; a_i 和 d_i 分别为第 i 个变量随机游走的最小值和最大值。

(2) 蚂蚁进入蚁狮陷阱

当蚂蚁进入蚁狮陷阱后, 蚂蚁的随机游走会受到陷阱的影响, 因此将蚂蚁的随机游走重新定义, 如下所示:

$$\begin{cases} c_i^t = Antlion_j^t + c^t \\ d_i^t = Antlion_j^t + d^t \end{cases} \quad (4-31)$$

式中, $Antlion_j^t$ 为第 j 个蚁狮在第 t 次迭代时的位置; c^t 和 d^t 分别表示第 t 次迭代过程时所有变量的最小值和最大值。

(3) 蚂蚁进入陷阱中心

蚂蚁进入陷阱后, 蚂蚁随机游走的范围减小, 可由式(4-32)和式(4-33)对该现象进行定义:

$$\begin{cases} c^t = \frac{c^t T}{10^w t} \\ d^t = \frac{d^t T}{10^w t} \end{cases} \quad (4-32)$$

$$w = \begin{cases} 2, t > 0.1T \\ 3, t > 0.5T \\ 4, t > 0.75T \\ 5, t > 0.9T \\ 6, t > 0.95T \end{cases} \quad (4-33)$$

式中, t 和 T 分别为当前迭代次数和最大迭代次数; w 是由 t 和 T 所决定的常数。

(4) 蚁狮捕获蚂蚁及重建陷阱

蚁狮捕获蚂蚁之后, 蚁狮会将自己的位置更新到被捕获蚂蚁的位置, 其定义如下所示:

$$Antlion_j^t = Ant_i^t \quad \text{if } f(Ant_i^t) > f(Antlion_j^t) \quad (4-34)$$

式中， Ant_i^t 为第 t 次迭代时第 i 个蚁狮的位置； $f(Ant_i^t)$ 和 $f(Antlion_j^t)$ 分别为蚁狮和蚂蚁的适应度函数。

(5) 精英策略

迭代过程中获得最优解的蚁狮被认为是精英蚁狮。此时，蚂蚁的位置会受到精英蚁狮和轮盘赌随机选择蚁狮的影响。蚂蚁位置的更新公式如下所示：

$$Ant_i^t = \frac{R_A^t + R_E^t}{2} \quad (4-35)$$

式中， R_A^t 和 R_E^t 分别为第 t 次迭代时轮盘赌随机选择蚁狮的位置和蚂蚁随机游走的位置。

4.3.2 MKRVM 模型

MKRVM 模型是 RVM 模型的一种扩展，其核心思想是将 RVM 模型中的单一核函数替换为多个核函数的线性组合，从而结合不同核函数的优点，进一步提高模型的预测性能^[63]。RVM 模型中核函数的种类有很多，不同的核函数所表现出的性能有所不同。下面介绍几种常见的核函数。

(1) 线性核函数

线性核函数是最简单的一种核函数，它能够很好地表示输入变量与输出变量之间单调递增或者单调递减的关系。虽然线性核函数对于线性问题的预测具有很好的表达能力，但是其难以准确表达大多数非线性问题的预测。线性核函数的表达式，如式（4-36）所示：

$$K_{Linear}(x_i, x_j) = x_i^T x_j \quad (4-36)$$

(2) Sigmoid 核函数

Sigmoid 核函数是一种典型的非线性核函数，其可以将输入变量映射到 Sigmoid 空间中。在实际应用中，通常 Sigmoid 核函数输出范围为[0,1]，输出范围有限且较为稳定。Sigmoid 核函数的表达式，如式（4-37）所示：

$$K_{Sigmoid}(x_i, x_j) = \tanh(a * x_i^T * x_j) \quad (4-37)$$

式中， a 为 Sigmoid 核函数的核参数。

(3) 高斯核函数

高斯核函数是一种局部核函数，其可以准确捕捉到非线性变化中的局部特

征。并且高斯核函数相对于其他核函数，只需要调整一个参数就可很好的适用于任意一个非线性样本的预测中，因此被广泛应用于各种数据驱动模型中。高斯核函数的表达式如式（4-11）所示。

（4）拉普拉斯核函数

拉普拉斯核函数本质上完全具备了高斯核函数的优点，并且可以有效处理非线性问题。拉普拉斯核函数的表达式，如式（4-38）所示：

$$K_{Laplacian}(x_i, x_j) = \exp(-\|x_i - x_j\| / \delta) \quad (4-38)$$

式中， δ 为拉普拉斯核函数的核参数。

（5）多项式核函数

多项式核函数的全局性较好，但是所含参数太多，使得模型复杂度较高。此外，随着多项式幂数的递增，模型计算量会显著增加。多项式核函数的表达式，如式（4-39）所示：

$$K_{Poly}(x_i, x_j) = (ax_i^T * x_j + c)^d \quad (4-39)$$

式中， a 、 c 和 d 为多项式核函数的核参数。

在 RVM 模型中，高斯核函数具有很好的非线性预测能力，并能准确捕捉到非线性预测中的局部特征，因而得以广泛应用。但是高斯核函数存在着全局性不强以及参数敏感度较高等问题。Sigmoid 核函数的全局性较强，可以有效弥补高斯核函数全局性不强的问题。拉普拉斯核函数本质上完全具备了高斯核函数的优点，并且相对于高斯核函数，其参数敏感性相对较低且计算速度较快。因此，本章将高斯核函数、拉普拉斯核函数以及 Sigmoid 核函数进行线性组合构成复合核函数，替代 RVM 模型中的单一核函数，从而建立 MKRVM 模型，以便能够准确描述锂电池 SOH 的退化趋势，进一步提高模型的预测精度。MKRVM 模型中复合核函数的表达式，如式（4-40）所示：

$$Kenel = \lambda_1 K_{Gaussian}(x_i, x_j) + \lambda_2 K_{Laplacian}(x_i, x_j) + \lambda_3 K_{Sigmoid}(x_i, x_j) \quad (4-40)$$

式中， λ_1 、 λ_2 和 λ_3 分别为 3 种核函数的权重参数，且 $\lambda_1 + \lambda_2 + \lambda_3 = 1$ 。

4.3.3 ALO-MKRVM 模型的预测流程

在 ALO-MKRVM 模型中，以健康特征 F1~F4 作为输入，锂电池 SOH 作为

输出，采用 MKRVM 模型对 SOH 进行预测。同时，为进一步提高 SOH 的预测精度，采用 ALO 算法对 MKRVM 模型中的参数进行优化。在 ALO 算法中，以 SOH 真实值和预测值之间的均方根误差（Root Mean Square Error, RMSE）作为适应度函数，如下所示：

$$f_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i^{ture} - T_i^{pre})^2} \quad (4-41)$$

式中， N 为训练集样本总数； T_i^{ture} 和 T_i^{pre} 分别为第 i 次循环 SOH 的真实值和预测值。

图 4-3 为基于 ALO-MKRVM 的锂电池 SOH 预测模型流程图，预测流程主要步骤如下：




图 4-3 基于 ALO-MKRVM 的锂电池 SOH 预测模型流程图

步骤 1：数据预处理。利用相应的滤波算法和计算公式，从锂电池运行状态相对规律的充电片段中提取第 3 章中所选择的健康特征 F1~F4。然后，将电池数据划分为训练集和测试集。

步骤 2：训练 ALO-MKRVM 模型。首先以训练集的健康特征 F1~F4 作为输入，锂电池 SOH 作为输出，采用 MKRVM 模型建立健康特征 F1~F4 与 SOH 的映射关系，然后利用 ALO 算法对 MKRVM 模型中的参数进行优化，从而完成 ALO-MKRVM 模型的训练。

步骤 3：锂电池的 SOH 预测。将测试集输入到训练好的 ALO-MKRVM 模型中，得到 SOH 预测值。

4.4 实验验证及分析

4.4.1 模型参数设置

在 ALO-MKRVM 模型中，ALO 算法以 SOH 真实值和预测值之间的 RMSE 作为适应度函数。同时，ALO-MKRVM 模型中的参数设置如下^[64]：蚂蚁和蚁狮的数量设为 30，最大迭代次数设为 15，参数 λ_1 、 λ_2 和 λ_3 的搜索上限设为 [1,1,1]，搜索下限设为 [0,0,0]。

4.4.2 性能评价指标

为从多方面准确评估模型的性能，本章引入平均绝对误差（Mean Absolute Error, MAE）、RMSE、以及决定系数（Coefficient of determination, R^2 ）3 个评价指标，具体表达式如下：

$$MAE = \frac{\sum_{i=1}^N |y_i - y_i^{real}|}{N} \quad (4-42)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - y_i^{real})^2}{N}} \quad (4-43)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y_i^{real})^2}{\sum_{i=1}^N (y_{average} - y_i^{real})^2} \quad (4-44)$$


式中， N 为测试集样本总数； y_i 和 y_i^{real} 分别为第 i 次循环 SOH 的预测值和真实

值； $y_{average}$ 为测试集 SOH 真实值的平均值。


3 个评价指标中 MAE 和 RMSE 的值越小，则表明模型的预测性能越好； R^2 的值越接近于 1，则表明预测曲线与实际的 SOH 曲线拟合程度越好。

4.4.3 50%训练集仿真结果与分析


本章分别采用 CALCE 数据集和实验室测试数据对 ALO-MKRVM 模型进行实验验证分析，并利用 MAE、RMSE 和 R^2 3 个评价指标与 BP 神经网络、SVR、RVM 以及 MKRVM 模型的预测结果进行对比分析。在本文中，CALCE 数据集的 4 块电池上均有 800 组循环老化数据，实验室测试数据中的 S1 电池、S2 电池和 S3 电池分别有 1000、1000 和 893 组循环老化数据。将 CALCE 数据集和实验室测试数据的前 50% 的循环老化数据作为训练集，剩下 50% 循环老化数据作为测试集，验证模型的预测性能。图 4-4 为基于 CALCE 数据集（50% 训练集）的 SOH 预测结果和误差。




(a) CS2-35 电池 SOH 预测结果




(b) CS2-35 电池 SOH 预测误差




(c) CS2-36 电池 SOH 预测结果




(d) CS2-36 电池 SOH 预测误差




(e) CS2-37 电池 SOH 预测结果



(f) CS2-37 电池 SOH 预测误差



(g) CS2-38 电池 SOH 预测结果



(h) CS2-38 电池 SOH 预测误差

图 4-4 基于 CALCE 数据集的 SOH 预测结果和误差（50%训练集）


从图 4-4 中可以看出，在 CALCE 数据集的 4 块电池上，几种模型在 50%训练集的条件下均能准确预测 SOH。相较于其它模型，ALO-MKRVM 模型的 SOH 预测误差曲线整体收敛趋势较好，并且其预测值更加接近于 SOH 真实值。

表 4-1 为基于 CALCE 数据集（50%训练集）的预测结果评价指标，其能更加直观地显示各模型的预测效果。由表 4-1 可知，在 CALCE 数据集的 4 块电池上，ALO-MKRVM 模型的 MAE 和 RMSE 分别不超过 1.96%和 2.61%， R^2 均大于 0.87，评价指标均在合理范围以内且优于其它模型。以 CS2-36 电池的预测结果为例进行具体分析，ALO-MKRVM 模型相较于 BP 神经网络、SVR、RVM 以及 MKRVM 模型，MAE 分别降低了 38.56%、15.88%、33.11%和 11.71%，RMSE 分别降低了 48.62%、25%、32.03%和 12.12%， R^2 分别提高了 0.103、0.030、0.044 和 0.013，充分表明了 ALO-MKRVM 模型相较于其它模型具有更高的预测精度。


表 4-1 基于 CALCE 数据集的预测结果评价指标 (50%训练集)

电池	评价指标	BP	SVR	RVM	MKRVM	ALO-MKRVM
CS2-35	MAE(%)	3.10	2.26	2.22	2.09	1.55
	RMSE(%)	3.93	3.63	3.00	2.97	2.35
	R^2	0.914	0.927	0.952	0.951	0.979
CS2-36	MAE(%)	3.19	2.33	2.93	2.22	1.96
	RMSE(%)	5.08	3.48	3.84	2.97	2.61
	R^2	0.863	0.936	0.922	0.953	0.966
CS2-37	MAE(%)	2.65	1.94	2.03	1.86	1.56
	RMSE(%)	3.86	2.80	2.64	2.42	2.19
	R^2	0.780	0.884	0.896	0.903	0.922
CS2-38	MAE(%)	2.98	2.11	2.15	2.04	1.86
	RMSE(%)	3.48	3.44	2.85	2.74	2.59
	R^2	0.750	0.756	0.833	0.845	0.870


图 4-5 为基于实验室测试数据 (50%训练集) 的 SOH 预测结果和误差, 表 4-2 为基于实验室测试数据 (50%训练集) 的预测结果评价指标。




(a) S1 电池 SOH 预测结果



(b) S1 电池 SOH 预测误差



(c) S2 电池 SOH 预测结果



(d) S2 电池 SOH 预测误差




图 4-5 基于实验室测试数据的 SOH 预测结果和误差（50%训练集）

表 4-2 基于实验室测试数据的预测结果评价指标（50%训练集）


电池	评价指标	BP	SVR	RVM	MKRVM	ALO-MKRVM
S1	MAE(%)	0.87	1.01	0.84	0.75	0.36
	RMSE(%)	1.07	1.11	0.94	0.87	0.54
	R^2	0.873	0.863	0.901	0.915	0.968
S2	MAE(%)	0.90	0.86	0.70	0.56	0.40
	RMSE(%)	1.10	0.96	0.98	0.63	0.42
	R^2	0.727	0.792	0.783	0.910	0.962
S3	MAE(%)	1.03	1.07	0.91	0.77	0.42
	RMSE(%)	1.18	1.15	1.05	0.91	0.60
	R^2	0.830	0.840	0.865	0.900	0.963

从图 4-5 和表 4-2 可知，实验室测试数据上的实验结果与 CALCE 数据集上的实验结果类似，ALO-MKRVM 模型的评价指标均为最优。在实验室测试数据上，ALO-MKRVM 模型的 MAE 均小于 0.42%，RMSE 均小于 0.60%， R^2 均大于 0.962，评价指标均在合理范围以内且明显优于其它模型。


从上述实验结果可知，ALO-MKRVM 模型能够通过第 3 章提取的健康特征对锂电池 SOH 实现准确预测，并且相较于其它模型预测精度有着明显提升，充分验证了 ALO-MKRVM 模型的有效性。

4.4.4 40%训练集仿真结果与分析


为进一步验证 ALO-MKRVM 模型的预测性能，将训练集的比例缩小为 40%。图 4-6 为基于 CALCE 数据集（40%训练集）的 SOH 预测结果和误差。




(a) CS2-35 电池 SOH 预测结果




(b) CS2-35 电池 SOH 预测误差




(c) CS2-36 电池 SOH 预测结果




(d) CS2-36 电池 SOH 预测误差




(e) CS2-37 电池 SOH 预测结果



(f) CS2-37 电池 SOH 预测误差



(g) CS2-38 电池 SOH 预测结果



(h) CS2-38 电池 SOH 预测误差

图 4-6 基于 CALCE 数据集的 SOH 预测结果和误差 (40%训练集)

通过图 4-6 可以看出，在 CALCE 数据集上，BP 神经网络和 SVR 模型在循环前期的预测曲线都能够很好的与真实的 SOH 曲线相吻合，但是随着循环次数的增加，BP 神经网络和 SVR 模型的预测曲线均出现较大程度的发散。同时，从图中也可以看出，ALO-MKRVM 模型的 SOH 预测误差曲线的收敛趋势略优于 RVM 模型和 MKRVM 模型。


表 4-3 基于 CALCE 数据集的预测结果评价指标（40%训练集）

电池	评价指标	BP	SVR	RVM	MKRVM	ALO-MKRVM
CS2-35	MAE(%)	2.78	2.13	2.36	2.02	1.66
	RMSE(%)	5.37	3.96	3.07	2.63	2.15
	R^2	0.850	0.918	0.951	0.964	0.976
CS2-36	MAE(%)	3.56	2.33	3.33	2.28	2.09
	RMSE(%)	6.12	4.46	4.06	3.08	2.77
	R^2	0.824	0.907	0.923	0.955	0.964
CS2-37	MAE(%)	3.37	2.52	2.31	1.95	1.61
	RMSE(%)	4.51	3.51	3.14	2.46	2.38
	R^2	0.723	0.833	0.866	0.918	0.923
CS2-38	MAE(%)	2.98	2.31	2.45	2.09	1.87
	RMSE(%)	4.06	3.48	3.40	2.76	2.54
	R^2	0.676	0.762	0.773	0.850	0.873


表 4-3 为基于 CALCE 数据集（40%训练集）的预测结果评价指标。由表 4-3 可知，在 CALCE 数据集的 4 块电池上，ALO-MKRVM 模型的 MAE 和 RMSE 分别不超过 2.09%和 2.77%， R^2 均大于 0.873，各项评价指标依然优于其它模型。以 CS2-36 电池的预测结果为例，MKRVM 模型相较于 BP 神经网络、SVR 和 RVM 模型，MAE 分别降低了 35.96%、2.15%和 31.53%，RMSE 分别降低了 49.67%、30.94%和 24.14%， R^2 分别提高了 0.131、0.048 和 0.032。而 ALO-MKRVM 模型相较于 MKRVM 模型，MAE 和 RMSE 分别降低了 8.33%和 10.06%， R^2 提高了 0.009。因此，充分说明了 ALO-MKRVM 模型的预测精度更高，其预测值更加接近于 SOH 真实值。

图 4-7 为基于实验室测试数据（40%训练集）的 SOH 预测结果和误差，从图中可以看出，在实验室测试数据上的实验结果与 CALCE 数据集上的实验结果类似，随着循环次数的增加，5 种模型的 SOH 预测曲线均逐渐偏离真实的 SOH


曲线。但是 ALO-MKRVM 模型相对于其它 4 种预测模型依然表现出较好的预测性能，其预测曲线与真实的 SOH 曲线最为贴近。




(a) S1 电池 SOH 预测结果




(b) S1 电池 SOH 预测误差




(c) S2 电池 SOH 预测结果



(d) S2 电池 SOH 预测误差



(e) S3 电池 SOH 预测结果



(f) S3 电池 SOH 预测误差

图 4-7 基于实验室测试数据的 SOH 预测结果和误差 (40%训练集)

表 4-4 为基于实验室测试数据 (40%训练集) 的预测结果评价指标。由表 4-4 可知，在实验室测试数据的 3 块电池上，ALO-MKRVM 模型的 MAE 分别为 0.33%、0.45%和 0.50%，RMSE 分别为 0.50%、0.48%和 0.70%， R^2 分别为 0.981、0.968 和 0.960，评价指标均在理想范围以内且显著优于其它模型。以 S1 电池的

预测结果为例，MKRVM 模型相较于 BP 神经网络、SVR 和 RVM 模型，MAE 分别降低了 23.68%、32.55%和 20.18%，RMSE 分别降低了 40.24%、33.78%和 16.24%， R^2 分别提高了 0.135、0.096 和 0.032。同时，ALO-MKRVM 模型相较于 MKRVM 模型，MAE 和 RMSE 分别降低了 62.07%和 48.98%， R^2 提高了 0.055，充分说明了 ALO-MKRVM 模型的预测精度优于其它几种模型。

表 4-4 基于实验室测试数据的预测结果评价指标（40%训练集）

电池	评价指标	BP	SVR	RVM	MKRVM	ALO-MKRVM
S1	MAE(%)	1.14	1.29	1.09	0.87	0.33
	RMSE(%)	1.64	1.48	1.17	0.98	0.50
	R^2	0.791	0.830	0.894	0.926	0.981
S2	MAE(%)	1.00	0.98	0.79	0.60	0.45
	RMSE(%)	1.20	1.13	1.10	0.71	0.48
	R^2	0.793	0.826	0.854	0.914	0.968
S3	MAE(%)	1.18	1.19	1.11	0.96	0.50
	RMSE(%)	1.35	1.38	1.32	1.06	0.70
	R^2	0.853	0.846	0.859	0.909	0.960

综上分析可知，当训练集缩小到 40%时，几种模型的预测精度均出现不同程度的发散，但是 ALO-MKRVM 模型的评价指标均在理想范围以内，且预测精度显著优于其它几种模型，进一步验证了 ALO-MKRVM 模型的有效性和准确性。

4.5 本章小结

本章首先分别介绍了 BP 神经网络、SVR 以及 RVM 模型的基本原理，然后针对单一核函数的 RVM 模型预测精度较低以及 MKRVM 模型中参数难以确定的问题，提出了一种基于 ALO-MKRVM 的锂电池 SOH 预测模型。最后，利用 CALCE 数据集和实验室测试数据进行实验验证，并与 BP 神经网络、SVR、RVM 和 MKRVM 模型的预测结果进行对比分析，结果表明 ALO-MKRVM 模型具有更高的预测精度和更好的稳定性。

第 5 章 基于融合数据驱动方法的锂电池 SOH 预测

5.1 引言

通过第 4 章中的理论与实验结果可知，锂电池老化过程中会出现局部的容量再生现象，并且容量再生现象是随机发生的，单一的数据驱动模型难以对这种现象进行准确预测。因此，为了进一步提高 SOH 的预测精度，本章提出了一种基于融合数据驱动方法的锂电池 SOH 预测模型。该融合模型由初始预测模型和误差补偿模型构成，二者分别采用 MKRVM 模型和 ELM 模型，并利用 ALO 算法分别对 MKRVM 模型和 ELM 模型中的相关参数进行优化。初始预测模型是在充电片段中提取到的健康特征 F1~F4 作为输入，SOH 初始预测值作为输出。误差补偿模型是以 SOH 初始预测值和健康特征 F1~F4 作为输入，对应的 SOH 初始预测误差作为输出。然后，通过误差补偿模型的输出对 SOH 初始预测值进行补偿，得到最终的 SOH 预测值。最后，利用 CALCE 数据集和实验室测试数据对 ALO-MKRVM-ELM 模型的有效性、鲁棒性以及先进性进行对比分析。

5.2 极限学习机基本原理

ELM 模型是一种单隐层前馈神经网络，其与 BP 神经网络在结构上很相似，均包含三层网络结构。然而，两者在训练机制上有所不同。BP 神经网络依赖误差反向传播调整模型参数，而 ELM 模型则通过不同的学习机制简化了训练过程。在 ELM 模型的训练过程中，隐含层节点数是唯一需要设定的参数，输入权重和隐藏层偏置均是随机生成的，输出权重则是根据输入权重和隐藏层偏置的变化而自适应调整的^[65]。

假设有 N 个随机训练样本，其中第 i 次输入量与输出量分别为 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T$ 和 $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T$ ， n 表示输入量的维度， m 表示输出量的维度，则 ELM 模型的输出函数如下所示：

$$y_j = \sum_{i=1}^L \beta_i g(w_i x_j + b_i), j=1, \dots, N \quad (5-1)$$

式中， L 为隐藏层节点数； β_i 为输出层的权重向量； w_i 和 b_i 分别为第 i 个隐含层

的输入权重和偏置； $g(\bullet)$ 为隐藏层的激活函数，其一般采用 Sigmoid 函数，表达式如下所示：

$$g(x) = \frac{1}{1+e^{-x}} \quad (5-2)$$

ELM 模型的训练目标是使得输出误差最小化，模型预测值无限逼近于训练样本的真实值，即可表示为：

$$\sum_{j=1}^N \|y_j - t_j\| = 0 \quad (5-3)$$

存在 β_i 、 w_i 和 b_i 使得：

$$t_j = \sum_{i=1}^L \beta_i g(w_i x_j + b_i), j=1, \dots, N \quad (5-4)$$

式中， β_i 可由下式表示：

$$\begin{cases} H\beta = Y \\ H = \begin{bmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_L x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 x_N + b_1) & \cdots & g(w_L x_N + b_L) \end{bmatrix}_{N \times L} \end{cases} \quad (5-5)$$

式中， H 为隐藏层的输出矩阵； β 为输出权重； Y 为期望输出矩阵。

在 ELM 模型中，当 w_i 和 b_i 随机确定后，隐藏层的输出矩阵 H 就变成一个确定的矩阵。此时 ELM 模型的训练目标则转化为求解输出权重 β ，其可由最小二乘法获得，如下所示：

$$\hat{\beta} = H^+ Y \quad (5-6)$$

式中， H^+ 是 H 的 Moore-Penrose 广义逆。

5.3 基于 ALO-MKRVM-ELM 的 SOH 融合预测模型

5.3.1 基于 ALO-ELM 的 SOH 误差补偿模型

为了获得更高的预测精度，减小预测结果的误差，有学者提出了误差补偿的思想^[66-67]。该思想是通过引入误差补偿模型来修正原始预测模型中的预测误差，从而提升预测结果的准确性和可靠性。由于 ELM 模型能够较快的完成训练过程且具有较好的泛化能力，因而被广泛用于误差补偿模型^[68-69]。目前，误差

补偿模型的输入大多采用原始输入数据或者其他外部因素，忽略了数据驱动模型的预测结果与预测误差之间也遵循着一定的逻辑关系。因此，本章将充分考虑预测结果和预测误差之间的逻辑关系，以健康特征 F1~F4 和 ALO-MKRVM 模型的 SOH 初始预测值作为模型的输入，对应的 SOH 初始预测误差作为模型的输出，采用 ELM 模型充分挖掘输入和输出之间的映射关系。同时，考虑到 ELM 模型中输入权值和隐藏层偏置均是随机生成的，导致预测结果具有很强的不确定性。因此，通过 ALO 算法对 ELM 模型中的输入权重和隐藏层偏置进行优化，进一步提高误差补偿模型的预测精度，从而建立基于 ALO-ELM 的 SOH 误差补偿模型。图 5-1 为基于 ALO-ELM 的误差补偿模型结构。




图 5-1 基于 ALO-ELM 的误差补偿模型结构

5.3.2 ALO-MKRVM-ELM 融合模型的预测流程

本章构建的基于 ALO-MKRVM-ELM 的锂电池 SOH 融合预测模型是由初始预测模型和误差补偿模型两部分构成的，二者分别采用 ALO-MKRVM 模型和 ALO-ELM 模型。基于 ALO-MKRVM-ELM 的锂电池 SOH 融合预测模型流程图如图 5-2 所示。在 ALO-MKRVM-ELM 模型中，首先由 ALO-MKRVM 模型生成 SOH 初始预测值，然后将 SOH 初始预测值、SOH 初始预测误差以及健康特征 F1~F4 构成新的数据集，用于训练 ALO-ELM 模型。最后，通过 ALO-ELM 模型生成的误差预测值对 SOH 初始预测值进行误差补偿，得到最终的 SOH 预测值。




图 5-2 基于 ALO-MKRVM-ELM 的锂电池 SOH 融合预测模型流程图

根据图 5-2，ALO-MKRVM-ELM 模型的预测过程主要分为以下步骤：

步骤 1：数据预处理。利用相应的滤波算法和计算公式，从锂电池运行状态相对规律的充电片段中提取第 3 章中所选择的健康特征 F1~F4。然后，将电池数据划分为训练集和测试集。

步骤 2：建立基于 ALO-MKRVM 的 SOH 初始预测模型。首先以训练集的健康特征 F1~F4 作为输入，锂电池 SOH 作为输出，对 MKRVM 模型进行训练，然后采用 ALO 算法对模型参数进行优化，从而完成 ALO-MKRVM 模型的训练。

步骤 3：建立基于 ALO-ELM 的误差补偿模型。首先，将步骤 2 中训练集的 SOH 初始预测值与 SOH 真实值对比得到 SOH 初始预测误差，然后将 SOH 初始预测值、健康特征 F1~F4 和 SOH 初始预测误差重新构成新的训练数据集，训练 ELM 模型，同时利用 ALO 算法对 ELM 模型中的输入权重和偏置参数进行优化，

从而完成 ALO-ELM 模型的训练。

步骤4：锂电池的 SOH 预测。将测试集输入到训练好的 ALO-MKRVM-ELM 模型中，将初始预测模型的输出值与误差补偿模型的输出值相叠加，得到最终的 SOH 预测值。

5.4 实验验证及分析

5.4.1 模型参数设置


ALO-MKRVM-ELM 模型是由 ALO-MKRVM 模型和 ALO-ELM 模型两部分组成。ALO-MKRVM 模型的参数设置与 4.4.1 节相同。在 ALO-ELM 模型中，ALO 算法以 SOH 初始预测误差和误差预测值之间的 RMSE 作为适应度函数。ALO-ELM 模型的相关参数设置如下^[70]：蚂蚁和蚁狮的数量设为 30；最大迭代次数设为 50；隐含层节点数设为 10；激活函数选用 Sigmoid 函数；输入权重和偏置参数的搜索上限设为[1,1]，搜索下限设为[0,0]。

5.4.2 基于单节电池数据的有效性验证


一般来说，训练集的样本越多，预测模型的训练效果越好。但是训练集和测试集的样本总数是恒定的，随着训练集样本的增多，测试集样本也会随之减少，因此会影响预测模型测试结果的可靠性。

综合考虑，本章将 CALCE 数据集和实验室测试数据的前 40%的循环老化数据作为训练集，剩下 60%循环老化数据作为测试集，分别利用 ALO-MKRVM 模型和 ALO-MKRVM-ELM 模型对 SOH 进行预测。图 5-3 为基于 CALCE 数据集的 SOH 预测结果和误差，图 5-4 为基于 CALCE 数据集的 SOH 误差预测结果。通过图 5-3 中的 SOH 预测结果可以看出，两种模型均可以有效预测 CALCE 数据集的锂电池 SOH，但与 ALO-MKRVM 模型相比，ALO-MKRVM-ELM 模型的预测曲线更加贴近于真实的 SOH 曲线，并能有效追踪锂电池的局部容量再生现象。同时，从 SOH 预测误差曲线可以看出，ALO-MKRVM-ELM 模型相较于 ALO-MKRVM 模型误差波动范围更小，整体收敛趋势更好。从图 5-4 中可以看出，ALO-ELM 模型的 SOH 误差预测值与初始预测误差之间的吻合度较高，从


而使得 ALO-MKRVM-ELM 模型能够有效克服初始预测模型误差的影响, 预测精度得到显著提升。




(a) CS2-35 电池 SOH 预测结果




(b) CS2-35 电池 SOH 预测误差




(c) CS2-36 电池 SOH 预测结果




(d) CS2-36 电池 SOH 预测误差




(e) CS2-37 电池 SOH 预测结果



(f) CS2-37 电池 SOH 预测误差




(g) CS2-38 电池 SOH 预测结果




(h) CS2-38 电池 SOH 预测误差


图 5-3 基于 CALCE 数据集的 SOH 预测结果和误差




(a) CS2-35 电池



(b) CS2-36 电池



(c) CS2-37 电池



(d) CS2-38 电池

图 5-4 基于 CALCE 数据集的 SOH 误差预测结果


表 5-1 为基于 CALCE 数据集的预测结果评价指标。由表 5-1 可知，在 CALCE 数据集的 4 块电池上，ALO-MKRVM-ELM 模型相较于 ALO-MKRVM 模型预测精度显著提升。ALO-MKRVM-ELM 模型的 MAE 分别为 0.47%、0.78%、0.83% 和 0.56%，RMSE 分别为 0.90%、1.33%、1.06% 和 0.96%， R^2 分别为 0.996、0.992、0.985 和 0.982，评价指标均在理想范围以内且优于 ALO-MKRVM 模型。


以 CS2-35 电池的预测结果为例，ALO-MKRVM-ELM 模型相较于 ALO-MKRVM 模型，MAE 和 RMSE 分别降低了 71.69%和 58.14%， R^2 提高了 0.02。

表 5-1 基于 CALCE 数据集的预测结果评价指标


电池	预测模型	MAE(%)	RMSE(%)	R^2
CS2-35	ALO-MKRVM	1.66	2.15	0.976
	ALO-MKRVM-ELM	0.47	0.90	0.996
CS2-36	ALO-MKRVM	2.09	2.77	0.964
	ALO-MKRVM-ELM	0.78	1.33	0.992
CS2-37	ALO-MKRVM	1.61	2.38	0.923
	ALO-MKRVM-ELM	0.83	1.06	0.985
CS2-38	ALO-MKRVM	1.87	2.54	0.873
	ALO-MKRVM-ELM	0.56	0.96	0.982

图 5-5 为基于实验室测试数据的 SOH 预测结果和误差，图 5-6 为基于实验室测试数据的 SOH 误差预测结果。






(e) S3 电池 SOH 预测结果




(f) S3 电池 SOH 预测误差


图 5-5 基于实验室测试数据的 SOH 预测结果和误差



(a) S1 电池



(b) S2 电池



(c) S3 电池

图 5-6 基于实验室测试数据的 SOH 误差预测结果

通过图 5-5 的 SOH 预测结果可以看出，在实验室测试数据上两种模型均可以有效预测锂电池 SOH 的退化趋势，但是 ALO-MKRVM 模型的预测值偏离 SOH 真实值的程度较大，而 ALO-MKRVM-ELM 模型的预测值更贴近于 SOH 真实值，一定程度上说明了 ALO-MKRVM-ELM 模型具有更好的预测性能。同时，

从图 5-6 可以看出, ALO-ELM 模型的 SOH 误差预测值与初始预测误差之间的吻合程度较高。随着循环次数的增加, ALO-ELM 模型的预测曲线与真实误差曲线偏离程度逐渐变大, 但是其依然能够准确跟随真实误差曲线的变化趋势, 因此一定程度上提高了 SOH 的预测精度。

表 5-2 为基于实验室测试数据的预测结果评价指标。由表 5-2 可知, 在实验室测试数据的 3 块电池上, ALO-MKRVM-ELM 模型的 MAE 分别为 0.13%、0.12% 和 0.16%, RMSE 分别为 0.21%、0.15%和 0.23%, R^2 分别为 0.996、0.997 和 0.994, 各项评价指标均优于 ALO-MKRVM 模型。以 S3 电池的预测结果为例, ALO-MKRVM-ELM 模型相比于 ALO-MKRVM 模型, MAE 和 RMSE 分别下降了 68%和 67.14%, R^2 提高了 0.034, 充分表明了 ALO-MKRVM-ELM 模型的预测精度显著优于 ALO-MKRVM 模型。


表 5-2 基于实验室测试数据的预测结果评价指标

电池	预测模型	MAE(%)	RMSE(%)	R^2
S1	ALO-MKRVM	0.33	0.50	0.981
	ALO-MKRVM-ELM	0.13	0.21	0.996
S2	ALO-MKRVM	0.45	0.48	0.968
	ALO-MKRVM-ELM	0.12	0.15	0.997
S3	ALO-MKRVM	0.50	0.70	0.960
	ALO-MKRVM-ELM	0.16	0.23	0.994


综上, 在 CALCE 数据集和实验室测试数据上的实验结果均表明, ALO-MKRVM-ELM 模型能够很好的找到健康特征与锂电池 SOH 之间的非线性映射关系, 相比于 ALO-MKRVM 模型具有更高的预测精度, 充分验证了 ALO-MKRVM-ELM 模型预测锂电池 SOH 的有效性。

5.4.3 基于多节电池数据的鲁棒性验证


为验证 ALO-MKRVM-ELM 模型的鲁棒性, 分别将 CS2-35 电池和 S1 电池的循环老化数据作为训练集, 其余同类型电池的循环老化数据作为测试集, 即对锂电池全生命周期下的 SOH 进行预测。图 5-7 为基于 CALCE 数据集的全生命周期 SOH 预测结果和误差。




(a) CS2-36 电池 SOH 预测结果




(b) CS2-36 电池 SOH 预测误差




(c) CS2-37 电池 SOH 预测结果



(d) CS2-37 电池 SOH 预测误差



(e) CS2-38 电池 SOH 预测结果



(f) CS2-38 电池 SOH 预测误差

图 5-7 基于 CALCE 数据集的全生命周期 SOH 预测结果和误差


通过图 5-7 可以看出，ALO-MKRVM 模型在循环中后期的 SOH 预测误差波动较大，但是经过误差补偿后得到的 ALO-MKRVM-ELM 模型能够准确预测锂电池老化过程中的容量再生现象，其预测值更加接近于真实值，预测误差得到大幅度降低。表 5-3 为基于 CALCE 数据集的全生命周期预测结果评价指标。

表 5-3 基于 CALCE 数据集的全生命周期预测结果评价指标

电池	预测模型	MAE(%)	RMSE(%)	R^2
CS2-36	ALO-MKRVM	1.94	2.63	0.973
	ALO-MKRVM-ELM	0.29	0.57	0.998
CS2-37	ALO-MKRVM	1.59	2.22	0.951
	ALO-MKRVM-ELM	0.45	0.75	0.994
CS2-38	ALO-MKRVM	2.05	3.17	0.865
	ALO-MKRVM-ELM	0.36	0.59	0.995

由表 5-3 可知，在 CALCE 数据集的 3 块电池上，ALO-MKRVM-ELM 模型的 MAE 均小于 0.45%，RMSE 均小于 0.75%， R^2 均大于 0.994。以 CS2-36 电池的预测结果为例，ALO-MKRVM 模型的 MAE、RMSE 和 R^2 分别为 1.94%、2.63% 和 0.973，而经过误差补偿后的 ALO-MKRVM-ELM 模型的 MAE 和 RMSE 分别降至 0.29%和 0.57%， R^2 则提高到 0.998，充分说明了在 CALCE 数据集的全生命周期预测中，ALO-MKRVM-ELM 模型相较于 ALO-MKRVM 模型具有更高的预测精度。

图 5-8 为基于实验室测试数据的全生命周期 SOH 预测结果和误差，由图可知，在实验室测试数据的两块电池上，ALO-MKRVM 模型的预测曲线无论是在循环初期还是在循环末期都与真实的 SOH 曲线存在着较大的偏离程度，而 ALO-MKRVM-ELM 模型的预测曲线始终贴近于真实的 SOH 曲线，二者偏离程度很小。






图 5-8 基于实验室测试数据的全生命周期 SOH 预测结果和误差

表 5-4 为基于实验室测试数据的全生命周期预测结果评价指标。由表 5-4 可知，在 S2 和 S3 电池上，ALO-MKRVM-ELM 模型相较于 ALO-MKRVM 模型，MAE 分别降低了 78.57%和 79.38%，RMSE 分别降低了 72.15%和 78.43%， R^2 则分别提高了 0.049 和 0.044。

表 5-4 基于实验室测试数据的全生命周期预测结果评价指标

电池	预测模型	MAE(%)	RMSE(%)	R^2
S2	ALO-MKRVM	0.70	0.79	0.946
	ALO-MKRVM-ELM	0.15	0.22	0.995
S3	ALO-MKRVM	0.97	1.02	0.953
	ALO-MKRVM-ELM	0.20	0.22	0.997

综上，在 CALCE 数据集和实验室测试数据上的全生命周期预测结果均表明，基于误差补偿后得到的 ALO-MKRVM-ELM 模型相较于 ALO-MKRVM 模型，其预测值更加接近于 SOH 真实值，并且能够准确预测锂电池老化过程中的容量再生现象，使得 SOH 预测误差显著降低，充分说明了 ALO-MKRVM-ELM 模型具有更高的预测精度和更强的鲁棒性。

5.4.4 对比实验验证

为进一步验证 ALO-MKRVM-ELM 模型的预测性能，将 ALO-MKRVM-ELM 模型与现有文献中的预测模型进行对比分析。为保证对比结果的客观性，采用与现有文献相同的预测起点（Starting Point, SP）和预测终点。文献[71]和文献[72]分别采用基于 ALO 算法优化的 SVR 模型和基于贝叶斯优化（Bayesian

Optimization, BO) 的 LSTM 模型。由于 ALO-SVR 模型的输出为锂电池容量, 因此在与 ALO-SVR 模型进行对比分析时, 将 ALO-MKRVM-ELM 模型的输出也设置为锂电池容量。图 5-9 和图 5-10 分别为 CS2-35 和 CS2-36 电池在文献[71]相同条件下的容量预测结果, 图 5-11 和图 5-12 分别为 CS2-37 和 CS2-38 电池在文献[72]相同条件下的 SOH 预测结果。




图 5-9 CS2-35 电池不同预测起点下的容量预测结果




图 5-10 CS2-36 电池不同预测起点下的容量预测结果




图 5-11 CS2-37 电池不同预测起点下的 SOH 预测结果




图 5-12 CS2-38 电池不同预测起点下的 SOH 预测结果

通过图 5-9~图 5-12 可以看出，在设置与其它文献相同的预测条件时，ALO-MKRVM-ELM 模型的预测曲线与真实的退化曲线偏离程度很小，并且 ALO-MKRVM-ELM 模型可以准确预测局部的容量再生现象。表 5-5 为 ALO-MKRVM-ELM 模型与其它模型的预测结果评价指标。

表 5-5 ALO-MKRVM-ELM 模型与其它模型的预测结果评价指标

电池	预测起点	预测终点	预测模型	MAE(%)	RMSE(%)
CS2-35	309	772	ALO-SVR ^[71]	1.60	2.64
			ALO-MKRVM-ELM	0.59	1.09
	386	772	ALO-SVR ^[71]	1.58	2.37
			ALO-MKRVM-ELM	0.57	1.02
CS2-36	294	734	ALO-SVR ^[71]	1.96	3.37
			ALO-MKRVM-ELM	0.45	0.66
	367	734	ALO-SVR ^[71]	1.32	2.17
			ALO-MKRVM-ELM	0.45	0.70
CS2-37	210	700	BO-LSTM ^[72]	1.58	2.02
			ALO-MKRVM-ELM	0.77	0.98
	280	700	BO-LSTM ^[72]	1.31	1.64
			ALO-MKRVM-ELM	0.68	0.85
CS2-38	210	700	BO-LSTM ^[72]	0.87	1.13
			ALO-MKRVM-ELM	0.44	0.58
	280	700	BO-LSTM ^[72]	0.56	0.73
			ALO-MKRVM-ELM	0.40	0.51

由表 5-5 可知，在相同条件下，ALO-MKRVM-ELM 模型的预测结果相较于

ALO-SVR 模型和 BO-LSTM 模型，预测精度均出现一定程度的提升。以 CS2-35 电池的预测结果为例，当预测起点为第 309 次循环时，ALO-MKRVM-ELM 模型的 MAE 和 RMSE 相较于 ALO-SVR 模型分别降低了 63.13%和 58.71%；当预测起点为第 386 次循环时，ALO-MKRVM-ELM 模型相较于 ALO-SVR 模型，MAE 和 RMSE 也分别降低了 63.92%和 56.96%。以 CS2-37 电池的预测结果为例，当预测起点为第 210 次循环时，BO-LSTM 模型的 MAE 为 1.58%，ALO-MKRVM-ELM 模型的 MAE 相对其降低了 51.27%，并且 ALO-MKRVM-ELM 模型的 RMSE 为 0.98%，仅为 BO-LSTM 模型的一半；当预测起点为第 280 次循环时，ALO-MKRVM-ELM 模型相较于 BO-LSTM 模型，MAE 和 RMSE 分别降低了 48.09%和 48.17%。

综上分析可知，ALO-MKRVM-ELM 模型相较于其它文献中的同类模型，在锂电池 SOH 预测精度上具有明显优势，一定程度上证明了 ALO-MKRVM-ELM 模型的先进性。

5.5 本章小结

本章针对单一数据驱动模型无法准确预测容量再生现象，导致 SOH 预测精度较低的问题，提出了一种基于 ALO-MKRVM-ELM 的 SOH 融合预测模型。首先，对 SOH 误差补偿模型的基本原理进行了介绍。然后，详细说明了 ALO-MKRVM-ELM 模型的预测流程。最后，利用 CALCE 数据集和实验室测试数据进行实验验证。结果表明，该融合模型不仅能够对锂电池 SOH 实现准确预测，还能准确捕捉到 SOH 退化趋势中的容量再生现象，相较于其它模型具有更高的预测精度和更强的鲁棒性，一定程度上验证了该融合模型的先进性。

第 6 章 总结与展望

6.1 全文工作总结

准确预测锂电池 SOH 是保障锂电池安全稳定运行的重要前提。本文在有效提取健康特征的基础上,较为系统地开展了基于数据驱动的锂电池 SOH 预测方法的研究,并利用 CALCE 数据集和实验室测试数据进行了实验验证。全文主要工作总结如下:

(1) 在详细阐述锂电池的内部结构和工作原理的基础上,对锂电池老化的影响因素进行了研究分析。为验证模型的性能,一方面搭建了电池测试平台,并开展锂电池循环老化实验,获取了相关的测试数据;另一方面,介绍了公开的 CALCE 数据集,将其作为测试数据的又一来源。

(2) 针对锂电池在实际应用中放电工况随机性很强的问题,从相对规律的充电片段中提取出可以间接反映 SOH 的健康特征,分别为等压升充电时间、容量增量曲线的峰值、容量增量曲线的峰面积以及循环次数。然后,通过健康特征与 SOH 之间的散点图定性分析了二者的相关性。在此基础上,为防止出现冗余健康特征,又通过 Pearson 和 Spearman 相关系数对健康特征与 SOH 的相关程度进行了定量评估。评估结果表明,所选取的健康特征与 SOH 均存在着较强的相关性,能够适用于 SOH 的准确预测。

(3) 提出一种基于 ALO-MKRVM 的锂电池 SOH 预测模型。在 MKRVM 模型中采用高斯核函数、Sigmoid 核函数和拉普拉斯核函数构成复合核函数替代 RVM 模型中的单一核函数。然后,采用 ALO 算法对 MKRVM 模型中的参数进行优化,从而建立 ALO-MKRVM 模型。最后,利用 CALCE 数据集和实验室测试数据对 BP 神经网络、SVR、RVM、MKRVM 以及 ALO-MKRVM 模型的预测性能进行对比分析。结果表明,无论是在 50%训练集还是 40%训练集的条件下,ALO-MKRVM 模型的预测精度均优于其它几种模型,验证了 ALO-MKRVM 模型的有效性和准确性。

(4) 为进一步提高 SOH 的预测精度,针对单一数据驱动模型无法准确预测容量再生现象的问题,提出一种基于 ALO-MKRVM-ELM 的 SOH 融合预测模

型。该模型由初始预测模型和误差补偿模型两个部分组成，初始预测模型为 ALO-MKRVM 模型，误差补偿模型为 ALO-ELM 模型。ALO-MKRVM 模型中以健康特征 $F1\sim F4$ 作为输入，SOH 初始预测值作为输出。ALO-ELM 模型中以 SOH 初始预测值和健康特征 $F1\sim F4$ 作为输入，SOH 初始预测误差作为输出。然后，通过 ALO-ELM 模型的输出值对 SOH 初始预测值进行误差校正，得到最终的 SOH 预测值。最后，利用 CALCE 数据集和实验室测试数据进行实验验证，结果表明 ALO-MKRVM-ELM 模型能够有效克服初始预测模型误差的影响，预测精度得到显著提升，且相较于其它模型具有更强的鲁棒性。

6.2 工作展望

本文针对如何提高锂电池 SOH 的预测精度开展了一定的研究工作，但由于受到实验条件和时间的限制，仍然有很多工作值得扩展和完善，主要包括：

(1) 本文使用的 CALCE 数据集和实验室测试数据中的环境温度和充放电工况均是恒定不变的。而在实际应用中，锂电池的环境温度和充放电工况均是随机变化的。因此，后续可以考虑开展环境温度和充放电工况随机变化的锂电池循环老化实验，进一步对本文的预测模型进行验证分析。

(2) 虽然本文提取的健康特征与 SOH 存在着较强的相关性，但是输入特征维度的不同对数据驱动模型的预测性能有着显著的影响。因此，后续可以对健康特征进一步优化，以提高预测的精确性和鲁棒性，并尽可能降低计算复杂度。

(3) 本文使用的 CALCE 数据集和实验室测试数据均为单体电池数据，但在实际应用中锂电池通常是以成组的方式使用。因此，下一步工作可以考虑将本文的预测模型扩展到锂电池组的 SOH 预测中。

参考文献

- [1] Shu X, Guo Y, Yang W, et al. Life-cycle assessment of the environmental impact of the batteries used in pure electric passenger cars[J]. *Energy Reports*, 2021, 7: 2302-2315.
- [2] Kumar R R, Alok K. Adoption of electric vehicle: A literature review and prospects for sustainability[J]. *Journal of Cleaner Production*, 2020, 253: 119911.
- [3] 朱晓庆, 王震坡, WANG Hsin 等. 锂离子动力电池热失控与安全管理研究综述[J]. *机械工程学报*, 2020, 56(14): 91-118.
- [4] Chombo P V, Laoonual Y. A review of safety strategies of a Li-ion battery[J]. *Journal of Power Sources*, 2020, 478: 228649.
- [5] 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.
- [6] Lipu M S H, Hannan M A, Karim T F, et al. Intelligent algorithms and control strategies for battery management system in electric vehicles: Progress, challenges and future outlook[J]. *Journal of Cleaner Production*, 2021, 292: 126044.
- [7] Liu K, Li K, Peng Q, et al. A brief review on key technologies in the battery management system of electric vehicles[J]. *Frontiers of mechanical engineering*, 2019, 14: 47-64.
- [8] Jiang J, Li T, Chang C, et al. Fault diagnosis method for lithium-ion batteries in electric vehicles based on isolated forest algorithm[J]. *Journal of Energy Storage*, 2022, 50: 104177.
- [9] 王振新, 秦鹏, 康健强等. 基于衰退机理的三元锂离子电池 SOH 的诊断与估算[J]. *电子测量技术*, 2020, 43(10): 7-13.
- [10] 付鹏宇. 基于人工智能的锂离子电池健康状态估计[D]. 吉林大学, 2023.
- [11] 顾菊平, 蒋凌, 张新松等. 基于特征提取的锂离子电池健康状态评估及影响因素分析[J]. *电工技术学报*, 2023, 38(19): 5330-5342.
- [12] Ge M F, Liu Y, Jiang X, et al. A review on state of health estimations and remaining useful life prognostics of lithium-ion batteries[J]. *Measurement*, 2021, 174: 109057.

- [13] Ng K S, Moo C S, Chen Y P, et al. 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.
- [14] Shen P, Ouyang M, Lu L, et al. The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles[J]. IEEE Transactions on vehicular technology, 2017, 67(1): 92-103.
- [15] Xu W, Wang S, Jiang C, et al. A novel adaptive dual extended Kalman filtering algorithm for the Li - ion battery state of charge and state of health co - estimation[J]. International Journal of Energy Research, 2021, 45(10): 14592-14602.
- [16] Wen J, Chen X, Li X, et al. SOH prediction of lithium battery based on IC curve feature and BP neural network[J]. Energy, 2022, 261: 125234.
- [17] 韩乔妮, 姜帆, 程泽. 变温度下 IHF-IGPR 框架的锂离子电池健康状态预测方法[J]. 电工技术学报, 2021, 36(17): 3705-3720.
- [18] 王英楷, 张红, 王星辉. 基于 1DCNN-LSTM 的锂离子电池 SOH 预测[J]. 储能科学与技术, 2022, 11(01): 240-245.
- [19] Bao Z, Jiang J, Zhu C, et al. A new hybrid neural network method for state-of-health estimation of lithium-ion battery[J]. Energies, 2022, 15(12): 4399-4414.
- [20] Galeotti M, Cinà L, Giammanco C, et al. Performance analysis and SOH (state of health) evaluation of lithium polymer batteries through electrochemical impedance spectroscopy[J]. Energy, 2015, 89: 678-686.
- [21] Zhang S, Guo X, Dou X, et al. A rapid online calculation method for state of health of lithium-ion battery based on coulomb counting method and differential voltage analysis[J]. Journal of Power Sources, 2020, 479: 228740.
- [22] Wang J, Liu P, Hicks-Garner J, et al. Cycle-life model for graphite-LiFePO₄ cells[J]. Journal of power sources, 2011, 196(8): 3942-3948.
- [23] Saha B, Goebel K. Modeling Li-ion battery capacity depletion in a particle filtering framework[C]. Annual Conference of the Prognostics and Health Management Society. 2009: 1-10.

- [24] 李鹏, 李立伟, 杨玉新. 基于 IBOA-PF 的锂电池健康状态预测[J]. 储能科学与技术, 2021, 10(02): 705-713.
- [25] Fang L, Li J, Peng B. Online estimation and error analysis of both SOC and SOH of lithium-ion battery based on DEKF method[J]. Energy Procedia, 2019, 158: 3008-3013.
- [26] 刘旂琦, 雷万钧, 刘茜等. 基于双自适应扩展粒子滤波器的锂离子电池状态联合估计[J]. 电工技术学报, 2024, 39(02): 607-616.
- [27] Wang X, Wei X, Dai H. Estimation of state of health of lithium-ion batteries based on charge transfer resistance considering different temperature and state of charge[J]. Journal of Energy Storage, 2019, 21: 618-631.
- [28] Chen Z, Mi C C, Fu Y, et al. Online battery state of health estimation based on Genetic Algorithm for electric and hybrid vehicle applications[J]. Journal of Power Sources, 2013, 240: 184-192.
- [29] Xiong R, Li L, Li Z, et al. An electrochemical model based degradation state identification method of Lithium-ion battery for all-climate electric vehicles application[J]. Applied energy, 2018, 219: 264-275.
- [30] 高仁璟, 吕治强, 赵帅等. 基于电化学模型的锂离子电池健康状态估算[J]. 北京理工大学学报, 2022, 42(08): 791-797.
- [31] Cen Z, Kubiak P. Lithium - ion battery SOC/SOH adaptive estimation via simplified single particle model[J]. International Journal of Energy Research, 2020, 44(15): 12444-12459.
- [32] Xia Z, Qahouq J A A. State-of-charge balancing of lithium-ion batteries with state-of-health awareness capability[J]. IEEE Transactions on Industry Applications, 2020, 57(1): 673-684.
- [33] Guo Y, Yang D, Zhang Y, et al. Online estimation of SOH for lithium-ion battery based on SSA-Elman neural network[J]. Protection and Control of Modern Power Systems, 2022, 7(3): 1-17.
- [34] Liu J, Liu X. An improved method of state of health prediction for lithium batteries considering different temperature[J]. Journal of Energy Storage, 2023, 63: 107028.
- [35] Feng H, Shi G. SOH and RUL prediction of Li-ion batteries based on improved

- Gaussian process regression[J]. Journal of power electronics, 2021, 21: 1845-1854.
- [36] Li X, Yuan C, Wang Z. State of health estimation for Li-ion battery via partial incremental capacity analysis based on support vector regression[J]. Energy, 2020, 203: 117852.
- [37] 李强龙, 孙建瑞, 赵坤等. 基于 IALO-SVR 的锂电池健康状态预测[J]. 电子测量与仪器学报, 2022, 36(01): 204-211.
- [38] Chen Z, Shi N, Ji Y, et al. Lithium-ion batteries remaining useful life prediction based on BLS-RVM[J]. Energy, 2021, 234: 121269.
- [39] Widodo A, Shim M C, Caesarendra W, et al. Intelligent prognostics for battery health monitoring based on sample entropy[J]. Expert Systems with Applications, 2011, 38(9): 11763-11769.
- [40] Chen Z, Zhang S, Shi N, et al. Online state-of-health estimation of lithium-ion battery based on relevance vector machine with dynamic integration[J]. Applied Soft Computing, 2022, 129: 109615.
- [41] 刘月峰, 赵光权, 彭喜元. 多核相关向量机优化模型的锂电池剩余寿命预测方法[J]. 电子学报, 2019, 47(06): 1285-1292.
- [42] 王萍, 弓清瑞, 张吉昂等. 一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J]. 电工技术学报, 2021, 36(24): 5201-5212.
- [43] 陈峥, 李金元, 舒星等. 基于混合神经网络的锂离子电池健康状态估算[J]. 昆明理工大学学报(自然科学版), 2022, 47(03): 87-95.
- [44] Chen Z, Xue Q, Xiao R, et al. State of health estimation for lithium-ion batteries based on fusion of autoregressive moving average model and elman neural network[J]. IEEE access, 2019, 7: 102662-102678.
- [45] Jiang Y, Zhang J, Xia L, et al. State of health estimation for lithium-ion battery using empirical degradation and error compensation models[J]. Ieee Access, 2020, 8: 123858-123868.
- [46] Zhang J, Wang P, Gong Q, et al. SOH estimation of lithium-ion batteries based on least squares support vector machine error compensation model[J]. Journal of Power Electronics, 2021, 21: 1712-1723.

- [47] Chen L, Wang H, Liu B, et al. Battery state-of-health estimation based on a metabolic extreme learning machine combining degradation state model and error compensation[J]. *Energy*, 2021, 215: 119078.
- [48] 程艺. 基于迁移学习的锂电池健康状况监测[D]. 重庆邮电大学, 2022.
- [49] 巩亚栋. 锂离子电池的健康状态估计及退役分选方法研究[D]. 中南大学, 2022.
- [50] Xiong R, Pan Y, Shen W, et al. Lithium-ion battery aging mechanisms and diagnosis method for automotive applications: Recent advances and perspectives[J]. *Renewable and Sustainable Energy Reviews*, 2020, 131: 110048.
- [51] 时玮. 动力锂离子电池组寿命影响因素及测试方法研究[D]. 北京交通大学, 2014.
- [52] 李肖辉, 陈北海, 古领先等. 锂离子电池健康状态评估方法研究进展[J]. *电源技术*, 2021, 45(06): 818-822.
- [53] He W, Williard N, Osterman M, et al. Prognostics of lithium-ion batteries based on Dempster-Shafer theory and the Bayesian Monte Carlo method[J]. *Journal of Power Sources*, 2011, 196(23): 10314-10321.
- [54] Yang D, Zhang X, Pan R, 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.
- [55] Chang C, Wang Q, Jiang J, et al. Lithium-ion battery state of health estimation using the incremental capacity and wavelet neural networks with genetic algorithm[J]. *Journal of Energy Storage*, 2021, 38: 102570.
- [56] 樊亚翔, 肖飞, 许杰等. 基于充电电压片段和核岭回归的锂离子电池 SOH 估计[J]. *中国电机工程学报*, 2021, 41(16): 5661-5670.
- [57] Lyu Z, Gao R, Li X. A partial charging curve-based data-fusion-model method for capacity estimation of Li-Ion battery[J]. *Journal of Power Sources*, 2021, 483: 229131.
- [58] Anseán D, García V M, González M, et al. Lithium-ion battery degradation indicators via incremental capacity analysis[J]. *IEEE Transactions on Industry Applications*, 2019, 55(3): 2992-3002.

- [59] Wang G, Lyu Z, Li X. An Optimized Random Forest Regression Model for Li-Ion Battery Prognostics and Health Management[J]. Batteries, 2023, 9(6): 332-348.
- [60] 倪裕隆. 基于 SVR 的锂离子电池剩余有效寿命预测方法[D]. 东北电力大学, 2020.
- [61] 张洋. 基于相关向量机的锂离子电池在线剩余寿命预测方法研究[D]. 国防科学技术大学, 2016.
- [62] Mirjalili S. The ant lion optimizer[J]. Advances in engineering software, 2015, 83: 80-98.
- [63] 侯小康, 袁裕鹏, 童亮. 基于改进相关向量机的锂电池剩余使用寿命预测[J]. 电源技术, 2024, 48(02): 289-298.
- [64] 朱家俊. 基于智能优化粒子滤波的多层次锂离子电池剩余寿命预测研究[D]. 吉林大学, 2022.
- [65] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [66] Jiao X, Zhang D, Song D, et al. Wind speed prediction based on VMD-BLS and error compensation[J]. Journal of Marine Science and Engineering, 2023, 11(5): 1082-1103.
- [67] Yang H, Cheng Y, Li G. A new traffic flow prediction model based on cosine similarity variational mode decomposition, extreme learning machine and iterative error compensation strategy[J]. Engineering Applications of Artificial Intelligence, 2022, 115: 105234.
- [68] 唐振浩, 王世魁, 曹生现等. 基于混合数据驱动算法的 SCR 氮氧化物排放量动态预测模型[J]. 中国电机工程学报, 2022, 42(09): 3295-3307.
- [69] Jiao X, Zhang D, Wang X, et al. Wind speed prediction based on error compensation[J]. Sensors, 2023, 23(10): 4905-4924.
- [70] Ge D, Zhang Z, Kong X, et al. Extreme learning machine using bat optimization algorithm for estimating state of health of lithium-ion batteries[J]. Applied Sciences, 2022, 12(3): 1398-1420.
- [71] 王瀛洲, 倪裕隆, 郑宇清等. 基于 ALO-SVR 的锂离子电池剩余使用寿命预测

- [J]. 中国电机工程学报, 2021, 41(04): 1445-1457+1550.
- [72] Meng H, Geng M, Han T. Long short-term memory network with Bayesian optimization for health prognostics of lithium-ion batteries based on partial incremental capacity analysis[J]. Reliability Engineering & System Safety, 2023, 236: 109288.

攻读硕士期间取得的学术成果

发表的学术论文：

- [1] 以第一作者发表 EI 检索国际会议论文一篇
- [2] 以第三作者在安徽工程大学学报上发表期刊论文一篇

申请的专利：

- [1] 一篇发明专利.（实质审查，第二作者，导师第一作者）
- [2] 一篇发明专利.（实质审查，第三作者，导师第一作者）

参与的基金项目：

- [1] 安徽省重点研究与开发计划. 2020.01.01-2022.12.31.
- [2] 安徽未来技术研究院企业合作项目.

致谢

白驹过隙，安工程学习生涯的即将结束。回想起入学安工程时的懵懂，到如今硕士毕业时的怀揣着对未来的憧憬步入社会，不禁感慨万千。

首先，我要感谢我的导师刘世林教授，从研一入学伊始，确定研究方向之后，总是不自觉的陷入焦虑，但刘老师以平易近人的育人态度让我对研究方向产生了浓厚的兴趣。本课题能够顺利完成，离不开刘老师的悉心指导。三年来，刘老师不仅教会我如何做好科研，而且还教会了如何做人做事。刘老师在科研上的严谨态度和生活做事的态度，将使我受益终生。师恩之情，铭记于心。

其次，我想感谢我的实验室同门：孙波、丁峰、李兆乾、黄世婧、师兄师姐以及师弟师妹们。硕士三年求学期间，我们朝夕相处，在各自的低落期时，总是鼓励对方，共同渡过了那些难熬的岁月，感谢缘分让我们相遇于 5018 实验室！

此外，还需要感谢我的家人。父母已过知命之年，仍为我在外奔波劳累，愧疚之情难以言表。每次周末电话时，总是能感觉父母和姐姐的关切爱护之情。与女友异地四年，虽千里之遥，心却相连。在人生的后半程中，让我们继续携手迎接美好的未来。感谢家人在求学路上，对我无私的关怀与关心。家人的支持永远是我前行的动力。

最后，感谢评审老师能够在百忙之中抽空对我的论文进行评阅，感谢您背后的辛苦付出，谢谢！

尚德敏学 唯实惟新

