

分类号：TM73

密 级：公开

学校代码：10363

学 号：2220310105



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题目 基于数据驱动的动力电池组
故障诊断方法研究

论 文 作 者

方乐

指 导 教 师

刘世林

学 科（专业）

电气工程

研 究 方 向

智能信息处理与应用

论文提交日期：2025年5月8日

分类号：TM73

单位代码：10363

密 级：公开

学 号：2220310105

题 目 基于数据驱动的动力电池组

故障诊断方法研究

题 目 Research on Data-Driven Fault Diagnosis

Methods for Power Battery Packs

学生姓名： 方乐

指导教师： 刘世林教授

专 业： 电气工程

研究方向： 智能信息处理与应用

论文答辩日期： 2025 年 05 月 8 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：方乐

日期：2025年5月8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：

方乐

指导教师签名

方乐

日期： 2025 年 5 月 8 日

日期： 2025 年 5 月 8 日

基于数据驱动的动力电池组故障诊断方法研究

摘要

随着全球经济和社会的迅速进步，环境污染和能源短缺问题日益突出，推动新能源发展、实现能源可持续利用已成为国际共识。因此，随着电动汽车的快速发展，作为其核心部件的动力电池产业同步蓬勃发展。其中，锂离子电池凭借能量密度高、循环寿命长等显著优势，已成为电动汽车的主要动力源。然而，近年来电动汽车自燃事故频发，其中多数与锂电池组密切相关。锂电池组是由大量单体通过串并联组成，其在生产和使用中可能出现难以察觉的短路故障和连接故障。若不及时处理这些故障，会显著降低锂电池组的安全性，从而危及乘客和车辆安全。因此，解决动力锂电池组故障诊断、定位及分类问题，已成为当前亟待攻克的技术难题。本文基于这一背景展开研究，主要工作内容如下：

（1）以动力锂电池组为研究对象，介绍其基本结构和工作原理，分析锂离子电池常见故障特性以及演化过程，搭建电池组测试平台并设计单故障和多故障实验方案。通过模拟电池组的短路故障和连接故障，获取其在多种工况下的电压数据，并通过移动平均滤波法对获取的数据进行去噪，从而为后续研究提供了充分的数据支撑。

（2）针对传统阈值方法难以诊断早期短路故障问题，提出一种

基于 Pearson 相关系数和核主成分分析（Kernel Principal Component Analysis, KPCA）的电池组早期短路故障诊断及定位方法。该方法利用电池组电压之间的 Pearson 相关系数作为输入特征，结合 KPCA 算法进行故障诊断，并通过 KPCA 算法的贡献图对故障电池进行定位。采用单故障实验数据进行验证，结果证明论文提出的方法能够及时诊断故障和定位故障电池，具有较好的先进性和鲁棒性。

（3）针对多故障分类问题，提出一种基于电压极差和长短期记忆网络（Long Short-Term Memory, LSTM）的电池组多故障诊断方法。该方法提取电池组电压数据的电压极差作为输入特征，结合 LSTM 算法对电池组正常、短路故障和连接故障三种状态进行分类诊断，并根据最大/最小电压电池号的变化图确定故障电池。采用多故障实验数据进行验证，并与其它三种算法的效果进行对比分析，结果证明了论文所提方法的有效性和泛化性。

关键词：动力锂电池组，故障诊断，Pearson 相关系数，Kernel Principal Component Analysis，电压极差，Long Short-Term Memory

RESEARCH ON DATA-DRIVEN FAULT DIAGNOSIS METHODS FOR POWER BATTERY PACKS

ABSTRACT

With the rapid progress of the global economy and society, environmental pollution and energy shortage issues have become increasingly prominent. Promoting the development of new energy and achieving sustainable energy utilization have become an international consensus. Therefore, with the rapid development of electric vehicles, the battery industry, as a core component, has also flourished. Among them, lithium-ion batteries, with their significant advantages such as high energy density and long cycle life, have become the main power source for electric vehicles. However, in recent years, there have been frequent self-ignition accidents of electric vehicles, most of which are closely related to lithium battery packs. Lithium battery packs are composed of a large number of individual cells through series and parallel connections, and they may have undetectable short-circuit faults and connection faults during production and use. If these faults are not dealt with in time, they will significantly reduce the safety of lithium battery packs, thereby endangering the safety of passengers and vehicles. Therefore, solving the problems of fault diagnosis, location and classification of power lithium battery packs has become a technical challenge that needs to be urgently addressed. This

paper is based on this background and the main research contents are as follows:

(1) Focusing on power lithium battery packs, this paper introduces their basic structure and working principles, analyzes the common fault characteristics and evolution processes of lithium-ion batteries, and establishes a battery pack testing platform while designing single-fault and multi-fault experimental schemes. By simulating short-circuit and connection faults in battery packs, voltage data under various operating conditions are collected. The acquired data are then denoised using moving average filtering, providing a robust dataset for subsequent research.

(2) To address the difficulty of traditional threshold-based methods in diagnosing early-stage short-circuit faults, a novel method for early short-circuit fault diagnosis and localization in battery packs is proposed, based on Pearson correlation coefficient and Kernel Principal Component Analysis (KPCA). This method uses the Pearson correlation coefficient between battery pack voltages as input features, combines the KPCA algorithm for fault diagnosis, and locates faulty cells through the contribution plot of KPCA. Validation using single-fault experimental data demonstrates that the proposed method can promptly diagnose faults and identify faulty cells, exhibiting strong performance and robustness.

(3) To tackle the multi-fault classification problem, a battery pack multi-fault diagnosis method based on voltage range and Long Short-Term

Memory (LSTM) networks is proposed. This approach extracts the voltage range of battery pack voltage data as input features and employs the LSTM algorithm to classify and diagnose three states of the battery pack: normal, short-circuit fault, and connection fault. The faulty cells are determined based on the variation patterns of the maximum/minimum voltage cell numbers. Validation using multi-fault experimental data, along with comparative analysis against three other algorithms, confirms the effectiveness and generalization capability of the proposed method.

KEY WORDS: Power lithium battery packs, Fault diagnosis, Pearson correlation coefficient, Kernel Principal Component Analysis, Voltage range, Long Short-Term Memory

目录

摘要.....	I
ABSTRACT.....	III
第 1 章 绪论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状.....	3
1.2.1 电动汽车发展进程.....	3
1.2.2 锂离子动力电池发展现状.....	3
1.2.3 锂离子电池故障诊断方法.....	5
1.3 论文主要内容与章节安排.....	9
第 2 章 锂离子电池故障特性分析及实验.....	11
2.1 引言.....	11
2.2 锂离子电池概述.....	11
2.2.1 锂离子电池的基本结构及工作原理.....	12
2.2.2 不同正极材料的锂离子电池.....	13
2.3 锂离子电池常见故障的演化过程分析.....	14
2.3.1 过充电故障和过放电故障.....	14
2.3.2 短路故障和连接故障.....	16
2.4 锂离子电池测试平台及故障实验方案.....	19
2.4.1 测试平台.....	19
2.4.2 单故障实验方案.....	20
2.4.3 多故障实验方案.....	22
2.5 实验数据获取及其预处理.....	23
2.5.1 移动平均滤波法.....	23
2.5.2 单故障数据获取及其预处理.....	24
2.5.3 多故障数据获取及其预处理.....	25
2.6 本章小结.....	26
第 3 章 基于 Pearson 相关系数和 KPCA 的电池组早期短路故障诊断方法.....	28
3.1 引言.....	28
3.2 方法与原理.....	28

3.2.1 相关系数原理	28
3.2.2 KPCA 故障诊断原理	29
3.2.3 基于 Pearson 相关系数和 KPCA 的电池组故障诊断流程	33
3.3 实验验证及分析	34
3.3.1 数据分析与特征提取	34
3.3.2 故障诊断模型性能测试	36
3.4 本章小结	41
第 4 章 基于电压极差和 LSTM 的电池组多故障诊断方法	43
4.1 引言	43
4.2 方法与原理	43
4.2.1 电压极差定义	43
4.2.2 LSTM 算法原理	43
4.2.3 LSTM 多故障分类模型	46
4.2.4 基于电压极差和 LSTM 的电池组多故障分类诊断模型	46
4.3 实验验证及分析	48
4.3.1 实验数据分析及特征提取	48
4.3.2 模型评价指标及特征长度确定	50
4.3.3 基于 LSTM 算法的多故障分类诊断模型性能测试	51
4.3.4 故障定位	53
4.3.5 诊断时间	55
4.4 本章小结	55
第 5 章 总结与展望	56
5.1 全文工作总结	56
5.2 工作展望	57
参考文献	58
攻读硕士期间取得的学术成果	65
致谢	66

第 1 章 绪论

1.1 研究背景及意义

汽车行业的快速发展深刻改变了社会生活，成为经济发展的重要支柱。然而，传统燃油汽车在带来便利的同时，也导致了石油危机和环境污染等问题^[1-4]。我国汽车年增量接近 3000 万辆，导致石油消耗和尾气排放持续上升，进一步加剧了能源安全和环境压力。由于石油储量有限且长期依赖进口，若不改变现状，能源安全将面临更大挑战^[5]。在此背景下，全球已认识到新能源汽车的重要性，其中，电动汽车凭借其环保和高效能源利用的优势，受到广泛关注和支持，推广电动汽车不仅能缓解石油资源枯竭与需求增长的矛盾，降低对进口石油的依赖，还能推动汽车产业向高效、可持续方向发展^[6]。我国政府积极出台多项政策，大力支持电动汽车产业的发展^[7-10]。动力电池作为电动汽车的核心组件，其发展也取得了显著进展，尽管动力电池种类众多，但其中锂离子电池凭借众多优势，已成为电动汽车的首选，而且随着锂离子电池技术的不断进步和电动汽车产量快速增长，使得锂离子电池需求量也在显著增长。据相关统计数据显示，2024 年全球锂离子电池的生产量为 1545.1GWh，比去年增长 28.5%，具体数据如图 1-1 所示^[11]。




图 1-1 全球锂离子电池出货量

尽管如此，随着电动汽车及其电池产业的蓬勃兴起，电池安全问题也在逐渐浮出水面，成为不容忽视的议题^[12-14]。近年来，包括理想、零跑、长城、大众等在内的众多知名电动汽车品牌频繁遭遇起火事件，这不仅对驾乘人员的生命安全构成了重大威胁，还深深触动了消费者对电动汽车安全性能的忧虑，使得安全问题在购车决策中占据了首要位置^[15-16]。根据相关统计数据显示，平均有一万辆电动汽车中就有一辆会发生自燃，虽然电动汽车自燃率已从 2021 年的万分之 1.85 降至 2023 年的万分之 0.96，但是其自燃率还是高于燃油汽车的，部分电动汽车安全事故如表 1-1 所示。

表 1-1 2023 年 1-6 月国内电动汽车部分安全事故

时间	地点	车型	电池类型	事故情况
2023.1.29	山东济南	理想 L9	三元锂电池	路旁停放起火
2023.2.11	浙江杭州	零跑 T03	三元锂电池	静止停放起火
2023.2.14	北京	比亚迪秦 PLUS BM-i	磷酸铁锂电池	行驶中起火
2023.2.21	广东东莞	比亚迪唐 DM	磷酸铁锂电池	行驶中起火
2023.2.26	广东深圳	哪吒 S	三元锂电池	充电时起火
2023.3.3	广东佛山	埃安 S	三元锂电池	停车起火
2023.3.27	河南平顶山	欧拉 IQ	三元锂电池	充电时起火
2023.4.4	海南三亚	大众 ID6	三元锂电池	行驶中起火
2023.4.24	海南文昌	云度 II3	磷酸铁锂电池	停车起火
2023.5.8	广东清远	岚图 free	三元锂电池	充电时起火
2023.6.13	安徽滁州	众泰云 100	三元锂电池	停车起火

锂离子电池组通常由大量电池单体通过串并联组合而成，以满足特定电压和容量需求，但由于其单体之间不一致性的存在，且对外界温度变化极为敏感，进而导致故障诊断十分艰难，也阻碍了电池安全管理的发展^[17]。因此，准确诊断锂离子电池故障对于确保其安全高效运行至关重要，也是保障电池管理系统（Battery Management System, BMS）稳定可靠的核心要素。尽管当前 BMS 能够识别显著故障并发出警报，但在面对早期、微小及特征不明显的故障时，其诊断能力不足，若这些潜在故障未能及时检测和处理，将在后续使用中累积并加剧，导致电池安全性能下降，从而演变为严重安全事故^[18]。因此，实现锂离子电池故障的超前准确诊断与分类，不仅能提高电动汽车的安全性，也能对人们的生命财产安全起到一定保护。

1.2 国内外研究现状

1.2.1 电动汽车发展进程

电动汽车的起源可追溯到 1834 年，早于燃油汽车的诞生。美国当时推出了首辆使用不可充电干电池的电动汽车，然后在 1881 年，法国的工程师取得重大突破，制造出了首辆可充电的铅酸蓄电池电动汽车，然而，受限于电池技术及内燃机技术的迅猛发展，电动汽车一度退出市场，当进入了 21 世纪后，为应对环境挑战和推动绿色转型，电动汽车又重新受到重视，成为汽车产业的主流趋势^[19-20]。

电动汽车与传统燃油汽车的核心差异在于动力系统，燃油汽车依赖化石燃料和内燃机，排放污染物，而电动汽车则依赖电池供电，通过电机驱动，具有环保和高效能转换的优势，因此，基于不同的工作方式，电动汽车主要分为纯电动、增程式和混动式三种类型^[21]。随着国家政策的大力扶持和市场需求的不断增长，推动了电动汽车产业的快速发展。据公安部不完全统计，截止 2023 年底，全国新能源汽车保有量为 2041 万辆，占全国汽车总量的 6.07%；其中纯电动汽车的保有量为 1552 万辆，占新能源汽车保有量的 76.04%。另外，在 2023 这一整年中，全国新注册登记新能源汽车 743 万辆，占新注册登记汽车数量的 30.25%，与 2022 年相比增加了 207 万辆，增长 38.76%，从 2019 年的 120 万辆到 2023 年的 743 万辆，呈现出高速增长的趋势。显然，电动汽车的市场正在快速扩张，并在保护环境和合理利用资源的背景下，其发展活力十分强劲。

1.2.2 锂离子动力电池发展现状

随着电动汽车需求量的快速增长，作为其核心组件的动力电池市场需求也持续攀升。目前，锂离子电池凭借其显著优势成为动力电池的主流选择，其市场规模正迅速扩大，其中锂离子电池根据材料不同可以分为三元锂电池、磷酸铁锂电池、钴酸锂电池和锰酸锂电池四种类型^[22-23]。这四种锂离子电池中，磷酸铁锂电池和三元锂电池的装车量最多，但两者性能还是有一定差别的。三元锂电池在电池容量、充放电倍率和环境适应能力方面的表现比磷酸铁锂电池好，但在电池安全运行和循环使用寿命方面表现比磷酸铁锂电池较差^[24]。所以随着电池安全事故的层出不穷，电池的安全性变得极其重要，也是电动汽车厂商选

择电池的重要指标^[25-28]。因此，近几年磷酸铁锂电池的装车量已超过三元锂的装车量。

根据中国汽车动力电池产业创新联盟的统计数据，2024 年我国动力电池累计装车量达到 548.4GWh，同比增长 41.5%。其中，磷酸铁锂电池装车量为 409GWh，占总装车量的 74.6%，同比增长 56.7%，其他材料电池装车量占比如图 1-2 所示。但电动汽车市场需求量还在不断增加，锂离子电池的需求量也随之增加，从而导致电池供应系统面临着巨大压力。为缓解这一局面，国轩高科、比亚迪、宁德时代等电池厂家纷纷扩产，积极加大产量的投入，从而推动动力电池产业进入快速发展阶段。




图 1-2 各种材料电池装车量占比图

动力电池的性能直接决定了电动汽车的运行质量，其关键特性包括安全性、续航能力和循环次数等^[29]。考虑电动汽车的发展需要，动力电池应满足以下核心标准。首先，安全性是重中之重，必须严格遵守动力电池的安全规范，并加强故障诊断与预测技术的研发；其次，能量密度需保持在较高水平，以提升续航能力，但同时需要平衡高能量密度与安全性之间的关系；第三，功率密度需足够大，以满足电动汽车的加速和爬坡需求；第四，使用寿命要长，充放电循环次数需足够多，以降低整车成本；第五，充电时间应尽量缩短，目前慢充时间为 6-8 小时，快充可在半小时之内充至 80%，但仍需进一步提升以满足消费者需求；第六，降低成本是关键，动力电池成本约占整车价值的 40%，经济性优势是电动汽车赢得市场的重要因素；第七，绿色环保需要贯穿电池全生命周期，从原材料开采到废弃处理都应尽量减少对环境的影响^[30]。

然而，动力电池在实际应用中面临复杂多变的运行环境，这对电池的安全性和稳定性提出了更高要求。市场监管总局数据显示，2024 年国内共有 385 辆新能源汽车被要求返厂处理，占全年总量的 34.3%，其中被要求返厂的主要原因是动力电池的制造缺陷。这些问题可能引发严重的安全隐患甚至事故，凸显了动力电池安全性能的重要性。因此，在追求高性能的同时，确保动力电池的安全稳定运行是行业发展的核心任务，也是推动电动汽车产业可持续发展的关键所在。

1.2.3 锂离子电池故障诊断方法

锂离子电池作为电动汽车的“动力源泉”，既是能量存储与释放的核心部件，也是主要的安全风险来源。为确保电池系统能够安全和可靠且稳定地运行，对锂离子电池进行及时准确的故障诊断至关重要。尽管有大部分人已在锂离子电池故障诊断领域投入了大量研究，但由于电池系统具有高度的非线性和温度敏感性，加之故障具有隐蔽性、多样性和动态演变的特点，同时受到外部环境和电池内部特性的双重影响，使得故障的精确诊断和类型辨别变得异常复杂^[31]。因此，锂离子电池的故障诊断仍是当前乃至未来相当长一段时间内亟待攻克的技术难题。

锂离子电池的常见故障可分为内部故障和外部故障两大类。内部故障主要包括内短路、过充电和过放电等问题，其中内短路故障尤为危险，因其通常伴随大量热量的快速释放，可能引发严重的安全事故^[32]。外部故障则主要为连接故障、外短路故障和传感器故障，这些故障早期时电池电气特性变化微小，难以诊断，随着电池不断运行，最后可能会导致热失控等安全事故发生^[33]。无论时内部故障还是外部故障。它们都会对锂离子电池的结构造成一定的破坏，导致其发生一些严重事故。

上述故障在早期时的电气特性的变化不明显，但它们的演化过程可能十分迅速，随着电池的持续运行，导致其发生严重的安全事故。因此，我们需要在早期时就对这些故障准确诊断，从而防止后续事故的发生。电池故障诊断的依据是电池特性发生异常变化，但电池内部特性难以获取，只能通过电压、电流和温度等电气特性对故障进行诊断。其中，当电池发生故障时电压变化较明显，当电压异常变大时，电池可能发生过充和连接故障；再当电池发生电压异常变

小时，电池可能发生短路故障和过放^[34-36]。因此，通过对这些特征参数的深入分析，可以为锂离子电池的故障诊断提供重要依据，从而提升电池系统的安全性和可靠性。目前对电池故障诊断的方法主要分为三种：基于知识的故障诊断方法、基于数据驱动的故障诊断方法和基于电池模型的故障诊断方法^[37]。图 1-3 概括了当前的研究状况。




图 1-3 锂电池故障诊断研究现状

基于知识的方法是一类基于故障树、有向图、专家系统和模糊逻辑的方法，它们不需要构建电池模型，而是提供大量电池运行数据的定性知识分析和模糊模型训练，从而发现数据特征和故障特性之间的关系^[38]。文献[39]提出了一种基于失效模式和影响分析（Failure Modes and Effect Analysis, FMEA）的模糊逻辑方法，用于电池组的风险评估，该方法旨在通过系统地分析电池组的功能、失效模式、原因和影响，从而减少故障的发生。文献[40]使用 FMEA 以及故障树分析（Fault Tree Analysis, FTA）来分析电动汽车起火事件，并将该方法用于电池系统的故障分析和设计试验，分析的重点是电池内部短路对电池系统和电动汽车的影响，通过分析开发出一种缓解故障发生的方法，以防止其引发火灾。然而，由于动力电池系统故障激发的复杂性以及信息表示和获取的困难性，建立有效的知识体系是一项巨大挑战，所以在电池故障诊断的研究上很少采用基

于知识的方法^[41-42]。

基于模型的方法涉及根据电池的电学和化学特性建立其数学模型，获取表征故障的参数，然后将模型估计值与实际测量参数进行比较以获得残差^[43-44]。接着，将残差与一组阈值进行比较，以判断故障是否发生。目前基于模型的故障诊断方法主要根据电压、电流和容量三种参数实现的。如文献[45]提出了一种基于模型的电压传感器故障诊断方法，该方法通过使用递归最小二乘法和扩展卡尔曼滤波融合算法来估计电池电压，再根据估计电压值与实际值的比较来诊断故障。还有文献[46]提出了一种基于等效电路模型和强跟踪扩展卡尔曼滤波器（Strong Tracking Extended Kalman Filter, ST-EKF）的故障诊断方法，该方法也通过电压残差来实现故障诊断。

除了利用电压特征，还有采用容量特征来实现故障诊断的，如文献[47]还提出了一种基于容量估计的电池故障诊断方法，该方法通过平均差异模型和扩展卡尔曼滤波算法来估计电池单体的荷电状态（State of Charge, SOC），再根据 SOC 差异实现故障诊断。以及文献[48]使用扩展卡尔曼滤波算法来估计电池组的 SOC，然后计算其与平均 SOC 的差异，以实现电池组的故障诊断。除了上述两种特征，还有部分学者采用电流特征来诊断故障，如文献[49]提出了一种基于改进等效电路模型的电池故障诊断方法，该方法结合使用最小二乘法和无味卡尔曼滤波器来检测电流传感器故障，该方法估计电流并将其与诊断阈值进行比较，以实现电流传感器的快速故障诊断。然而，电池是一个复杂且高度非线性的时变系统，电池的老化、运行环境等因素会给模型的建立带来一定困难，从而导致故障诊断的精确度低、鲁棒性差。

近年来，基于数据驱动的电池故障诊断方法受到了广泛关注。大致来说，基于数据驱动的方法可以分为三类：信号处理、信息融合以及机器学习，这类方法无需构建电池模型，也适用于不同故障的诊断场景^[50-51]。文献[52]提出了一种基于卷积神经网络-长短期记忆网络（Convolutional Neural Network and Long Short-Term Memory, CNN-LSTM）的故障预测方法，该方法利用 CNN-LSTM 预测电池模块中每个电池单体的电压，然后通过相关性分析获得预测值与实际值之间的关系，以确定是否有电池出现故障。文献[53]提出了一种基于电压余弦相关性的电池短路故障诊断方法，该方法利用电压和电流构建二维特征向量，

并引入具有激励信息的增益乘数对特征向量进行二次处理，从而分离故障信号特征并有效诊断电池故障。文献[54]提出了一种基于香农熵改进的电池故障诊断方法，该方法首先计算移动窗口内电压的香农熵，然后根据定义的灵敏度因子评估电压异常。值得注意的是，数据驱动方法依赖于大量历史数据进行训练，因此历史数据的数量和可靠性对故障诊断有一定影响。在电池早期微短路故障的情况下，电压异常变化可能不明显，这使得数据驱动方法难以检测到这些变化，从而导致故障诊断率较低。文献[55]也提出了一种名为 BERTtery (Bidirectional Encoder Representations from Transformers for batteries) 的专用 Transformer 网络模型，利用该模型可以在电池实际运行环境中对其进行故障诊断。

上述研究的对象都是单一故障，但在实际运行中，电池是具有多种故障，如果仅仅确定有故障发生，而无法确定故障类型，这样会对电池后期的安全性造成一定影响。因此，多故障类型的区分也是故障诊断的一个研究目标。目前，国内外学者对多故障分类诊断也有一定的研究，如文献[56]通过采用交错式电压测量电路，提出了一种基于随机卷积核变换和高斯过程分类器的电池组多故障诊断方法。文献[57]也根据非冗余交错式电压测量电路，提出了一种基于统计分析的电池组多故障诊断方法。文献[58]提出了一种增量电池电压测量拓扑，然后在这基础上提出了一种使用深度学习和自动编码器 (Auto Encoder, AE) 的电池组多故障诊断方法，其使用原始输入特征和 AE 重建的特征之间的残差作为故障指示器，最后通过残差是否超过阈值来进行多故障诊断。

这些研究都是基于交错式电压测量电路提出的一些诊断方法，但也有一些研究根据正常电压测量电路提出的多故障诊断方法，如文献[59]基于曲线曼哈顿距离和电压差分析，提出了一种锂离子电池组的快速多故障诊断方法。还有文献[60]根据电热模型，提出了一种自适应阈值方法，在考虑四种不同故障条件下电压和温度的变化率，实现了电池快速故障诊断。文献[61]也基于充电电压，提出了一种多故障诊断方法，其先计算与电池电压相关性高的特征并将其作为输入量，再通过极限梯度提升算法 (eXtreme Gradient Boosting, XGboost) 进行电压预测，从而提高与真实值对比实现故障诊断，最后通过空间聚类算法实现电池组的早期多故障分类与定位。

1.3 论文主要内容与章节安排

本文以动力锂电池组为研究对象，在分析其工作原理以及故障特性的基础上，主要针对锂电池组的故障特征提取和故障诊断方法进行研究。本文的总体框架如图 1-4 所示，各章的主要内容如下：




图 1-4 全文框架图

第 1 章，绪论。首先介绍了本课题的研究背景以及意义，然后，总结了目前国内外在该领域相关的研究现状，并介绍了国内外学者在故障诊断方法研究上的最新进展。最后，对本文的主要研究内容进行了简要说明。

第 2 章，锂离子电池故障特性分析及实验。在本章节，首先介绍了锂离子电池的基本结构和工作原理，然后，详细分析了锂离子电池常见故障的特性以及演化过程。最后，根据上述的分析，搭建了锂电池组的故障实验平台，并开展单故障以及多故障实验，获取相应的电压数据，再利用移动平均滤波法对获取数据进行去噪，为后续研究提供数据支撑。

第 3 章，基于 Pearson 相关系数和 KPCA 的电池组早期短路故障诊断方法。在本章首先对相关算法原理进行分析，并且介绍了一种基于 Pearson 相关系数和核主成分分析（Kernel Principal Component Analysis, KPCA）的电池组早期短路故障诊断及定位方法，然后在单故障实验数据的基础上，进行多种对比实验，验证其先进性及鲁棒性。

第 4 章，基于电压极差和 LSTM 的电池组多故障诊断方法。首先介绍了电压极差和长短期记忆网络（Long Short-Term Memory, LSTM）的基本原理，并且说明了基于电压极差和 LSTM 的电池组多故障分类诊断方法的主要流程。最后，根据多故障实验的电压数据，与其它算法进行对比实验，以准确率为评价指标，对本章所提方法的泛化性和有效性进行验证。

第 5 章，总结与展望。总结本文的研究工作和成果，然后根据本文研究的不足之处，对下一步的研究进行展望。

第 2 章 锂离子电池故障特性分析及实验

2.1 引言

锂离子电池作为电动汽车的能量存储核心，由于其内部结构复杂且运行机理多样，使得其在运作过程中可能遭遇的故障诱因既多变又难以预测，这无疑增加了故障诊断的难度并降低了诊断的准确性。鉴于此，本章首先深入探讨了锂离子电池的基础构造和运行原理，随后细致分析了锂离子电池中常见故障的发展演变路径及其触发因素。最终，为了获取精确且可靠的锂离子电池故障数据，本文构建了一个电池测试平台，并合理设计了一系列故障实验方案，并利用移动平均滤波法对原始数据进行去噪，这些数据将为后续基于数据驱动的故障诊断技术的研发提供坚实的实证基础。

2.2 锂离子电池概述

电池技术的发展历程已跨越近两个世纪，从早期的锌锰干电池等一次性电池，逐步演进至可重复充电的铅酸电池、镍镉电池、镍氢电池，再到如今广泛应用的锂离子电池，这一进程始终伴随着技术的持续探索与革新^[62]。锂离子电池的起源可追溯至 20 世纪 60 年代，其发展历程从初期的缓慢进步到后来的迅猛扩张，最终成为多个领域的核心能源技术。在研究的初期阶段，锂离子电池主要采用金属锂作为负极材料，但这种设计存在显著缺陷。在电池使用过程中，负极表面容易生成锂枝晶，一旦锂枝晶生长到足以穿透隔膜的程度，就会引发电池内部短路，导致温度急剧升高，甚至可能引发火灾或爆炸等严重安全事故。这一安全隐患成为锂离子电池早期发展的主要障碍。随后，时任加拿大蒙特利尔大学化学系的 Armand 教授提出了一项创新性解决方案，即采用嵌入化合物替代传统的正负极材料，这一技术突破有效解决了金属锂负极产生的锂枝晶问题，显著提升了锂离子电池的安全性能。在此基础上，锂离子电池领域迎来了新的发展高潮，以钴酸锂、锰酸锂、磷酸铁锂等为正极材料的新型电池相继问世^[63]。这些新型电池在能量密度、循环寿命和安全性等方面实现了显著提升，推动了锂离子电池技术的快速发展。

2.2.1 锂离子电池的基本结构及工作原理

锂离子电池的主要组成部分为正极、负极、隔膜和电解液。其中，正极和负极的材料都有着锂离子嵌入与脱嵌的能力，因为它们的晶体结构为锂离子的反应提供了场地。电解液是一种含有金属盐的溶液，其扮演着在电池内部传输锂离子的角色，而隔膜是一种聚合物物质，它位于电池的正负极之间，起到关键的隔离作用，防止电池的正负极短接。另外，隔膜独有的非导电性，使得电子不能通过，只有离子才能通过，从而实现电池的充放电功能。锂离子电池的工作原理如图 2-1 所示。





图 2-1 锂离子电池的工作原理图

从图 2-1 可知，锂离子电池在充电和放电的时候，锂离子会在电池的正极和负极之间反复嵌入与脱嵌。具体来说，当电池充电时，正极材料中的锂离子会析出，通过电解液和隔膜进入到负极材料中，进而实现了电能转换成化学能，使得电能储存到电池之中。再当电池放电的时候，负极材料中的锂离子会脱离，通过电解液和隔膜进入到正极材料中，从而实现电能的释放^[64]。本章以磷酸铁锂电池为例，电池充放电时主要的化学反应如下：


电池正极的化学反应方程式：



电池负极的化学反应方程式：



电池内部总化学反应方程式：



2.2.2 不同正极材料的锂离子电池

锂离子电池的正极材料在提供锂离子方面起着关键作用，其选择直接影响锂离子电池的多个性能指标，包括安全性、电池容量和充放电倍率，此外，正极材料还与电动汽车的可行驶里程和安全性密切相关^[65]。

当前，锂离子电池的正极材料主要采用磷酸铁锂、三元锂、锰酸锂和钴酸锂，且它们都具有不一样的结构^[66]。在这些材料中，磷酸铁锂的使用率最高，主要是因为其安全性较好，并且磷酸铁锂使用的原材料价格不高和开采过程环保。但是，磷酸铁锂在能量密度方面相较于其它材料稍显逊色。如三元锂具有融合其中所有金属的特性，让其也成为了当前最具发展前景的正极材料之一，且三元锂内部的金属随着占比不同，也会具有不一样的特性，但普遍都有着能量密度高的特性。锰酸锂的优势在于成本低廉、安全性高以及锰资源丰富，但稳定性较差，易导致电池容量逐渐下降。至于钴酸锂，尽管它拥有高能量密度和良好的稳定性，但钴资源的稀缺性和高昂价格成为了其显著劣势，更重要的是，其安全性能相对较差。

表 2-1 锂离子电池性能对比

电池类型	简称	能量密度	循环寿命	安全性	成本
磷酸铁锂电池	LFP	中	高	高	低
镍钴锰三元锂电池	NCM	高	高	低	中
镍钴铝三元锂电池	NCA	高	中	低	中
锰酸锂电池	LMO	低	中	中	低
钴酸锂电池	LCO	中	低	低	高

每种材料都有着不一样的优点和缺点，使得它们制造成的锂离子电池也有着不一样的特性。具体而言，在能量密度方面，磷酸铁锂电池表现较差，但凭借其在安全性、成本效益及使用寿命上的显著优势，在商用车领域（诸如公交车、货运车辆等）应用十分广泛。相比之下，三元锂电池有着较高的能量密度，且能适应不同的温度环境，但其在安全性方面，不如磷酸铁锂电池，进而使其应用市场正在不断减小。然后在价格方面，锰酸锂电池是最便宜的，但其在使

使用寿命和能量密度方面表现较差，使其很少被作为动力电池使用。最后钴酸锂电池在价格和安全性方面表现都差，使其也不能被广泛的应用在电动汽车上。

表 2-1 全面归纳并对比了不同正极材料所制成的锂电池的各项性能指标。

2.3 锂离子电池常见故障的演化过程分析

锂离子电池作为动力电池被应用在电动汽车上，其性能对电动汽车的发展有着很大的影响，尤其是安全性能。近年来，电动汽车起火事件屡见不鲜，其中超过七成的事故根源可追溯到锂离子电池，这一现象引起了人们的广泛关注。实际上，锂离子电池在制造过程中，由于其制造工艺和材料原因，使得锂离子电池存在一定的制造缺陷，进而导致电动汽车发生起火和爆炸等安全事故。从上述对不同正极材料电池的分析可知，磷酸铁锂电池的安全性较高，但也不可避免地发生一些安全事故。因此，本文聚焦于磷酸铁锂电池，旨在深入理解电池故障的触发机制和演变过程，进而开发出精确可靠的故障诊断技术。

2.3.1 过充电故障和过放电故障

为提高电动汽车的续航里程，锂离子电池组通常由大量电池单体通过串并联组合而成，从而提高其容量。然而，制造缺陷和使用不当会导致电池单体性能差异，即使电池组整体性能良好，也可能出现部分单体过充或过放问题。若充放电管理不当，还可能引发局部电池的过充或过放故障。这些故障若未能及时诊断，会对电池的安全运行造成一定严重影响^[67]。

锂离子电池在过充状态下会发生一系列复杂的副反应，严重影响电池性能和安全性：在负极方面，过量的锂离子无法正常嵌入负极材料，会在表面还原形成金属锂（析锂现象）。这些金属锂会使得后续的锂离子难以进入负极材料中，进而在负极的表面形成锂枝晶，使得电池的容量大大减少，而且随着电池的不断充电，这些锂枝晶会通过隔膜，使得电池的正负极短接，从而引发内短路故障。在电池的正极上，由于不断的释放锂离子，导致其结构遭到破坏，然后随着电池电压的不断上升，正极材料还会分解出氧气，这些氧气会使得电解液的氧化分解速度加快，从而产生大量热量和气体，进一步加剧电池的不稳定性^[68]。电解液在过充的条件下同样面临严峻挑战，随着电池内部温度和压力的持续升高，电解液的化学稳定性显著下降，发生分解反应并产生大量气体。这不仅会

导致电池膨胀，还可能造成壳体破裂，最终引发热失控，其具体原理图如图 2-2 所示。




图 2-2 过充原理图

此外，电池中的金属杂质（如铁）在过充的条件下也会参与氧化还原反应，在正负极之间形成金属枝晶，成为另一个潜在的短路通道。因此，根据过充的程度不同，电池受损情况可分为两个等级：

轻度过充：主要表现为负极析锂和锂枝晶生长，虽不会立即引发热失控，但会显著增加电池内部短路的风险；

深度过充：主要表现为电池内部温度持续上升，产生大量气体，使得内部压力也持续升高，使得正极材料结构受到破坏和电解液氧化分解，最终造成内部短路，进而演变成严重的热失控事故。

同样过放电也会造成一定的隐患，当电池轻微过放电时，电池的负极会释放出过多的锂离子，使得负极材料结构遭到破坏，从而导致电池的容量不断减小，使用寿命大大减少^[69]。再当电池长时间过放电时，电池的电压会不断降低，负极铜箔也会发生氧化反应，变成铜离子。这些铜离子会通过隔膜到达正极，然后在正极表面还原沉积，其反应过程如图 2-3 所示。这一过程不仅使得锂离子不能正常传输，导致电池容量下降，还能形成铜枝晶，并且随着铜枝晶的生长，进而导致电池正负极短接，电池内部温度不断上升，最终引发热失控等安全事故。最后在电池深度过放电时，大量的锂离子会进入正极材料中，导致其

结构发生变化，这种变化会降低电池的安全性能，可能会引发起火和爆炸等极端事故发生。因此，电池管理系统必须对过放电现象给予充分重视，通过电压监控、容量估算等手段，确保电池始终工作在安全电压范围内，避免因过放电导致的性能衰减和安全事故。




图 2-3 过放原理图

综上所述，无论是过充还是过放，都会对锂离子电池造成严重损害，显著缩短其循环寿命和引发一些安全事故。尤其是过充产生的锂枝晶和过放导致的铜枝晶，它们会破坏隔膜的结构，从而引发电池内部短路，使得电池内部温度不断上升。若无法在故障初期迅速且准确地识别问题，将极易引发热失控，对人员和车辆安全构成严重威胁。因此，对电池的过充和过放问题必须给予高度重视，并通过有效的管理和诊断技术加以防范。

2.3.2 短路故障和连接故障

电池经过长时间的过充和过放都会引发电池内部短路，然后电池内部温度持续上升，进而引发热失控等安全事故，因此短路故障相较于过充/过放故障存在更大的安全隐患。按照短路产生原因，短路故障可以分为外短路故障和内短路故障。再从故障的起因及其发展过程来看，电池内部短路的成因复杂多样。一方面，电池在生产制造过程中可能存在的缺陷会导致内部短路，例如金属杂质的混入、极片涂布不均匀、隔膜材料质量不佳等问题。这些问题通常较为隐蔽，不会立即导致热失控，但随着时间的推移，其存在的安全隐患会越来越大。

另一方面，当电池过充和过放时，其产生的枝晶会对隔膜的结构造成破坏，从而引发内部短路，导致内部温度不断升高，且内部气压也随着温度升高而升高，最终发生热失控，可能还会发生爆炸。此外，在电池的日常使用过程中，可能由于外界的因素使得电池结构发生变化，如针刺和挤压，这些都属于机械滥用，它们会使得电池内部隔膜结构遭到破坏，使得正负极内部短接，从而发生内短路，这些机械因素具有未知性，导致难以预测和诊断^[70]。内短路故障的诱因具体如图 2-4 所示。值得注意的是，内部短路故障具有隐蔽性和演化性，其故障特征不明显，容易被其他故障所掩盖，同时，由于故障发生时会使温度上升，电池内部压力增大，导致其内部积累着大量热量，最终发生热失控或者发生起火和爆炸等严重事故。




图 2-4 内短路故障的诱因

外短路故障是由于电池的正负极在电池外部直接相连所引发的，导致故障发生的原因主要为电池导电线破损和有不绝缘物体侵入^[71]。当电池发生外短路故障时，电池正负极被短接，然后有很大的电流通过导体，导致温度异常升高，而且电池的电压也会异常下降，如果不能及时诊断外短路故障，可能会对电池造成不可逆的损伤，甚至发生热失控，进一步导致电池发生起火和爆炸等严重事故。综上所述，内短路故障和外短路故障发生时都会使电池有大电流通过、

温度异常升高和电压异常下降，甚至会使电池发生热失控，进一步导致电池起火或者爆炸。短路故障具体演化过程如图所示，如果不能在早期对短路故障进行准确诊断，随着时间的流逝，可能会发生严重的安全事故。




图 2-5 短路故障演化过程

除了短路故障，连接故障同样是电动汽车发生火灾、爆炸等安全事故的一个重要诱因。电池发生连接故障时的主要表现为：当电池运行在剧烈振动和恶劣的环境下，会使得电池遭受机械应力和电池螺栓松动或脱落，使得电池单体之间的连接电阻增大，或者电池之间的连接片断开，进而导致电池的温度升高，内部特性发生变化，使得电池容量减小和使用寿命减短，还可能引发热失控等重大故障，具体的演化过程如图 2-6 所示^[72-73]。与短路故障一样，连接故障在早期时的特征极其隐蔽，导致基于阈值的传统方法难以诊断，但随着时间的累积，连接故障会进一步演变为重大故障，对电电动汽车的安全运行造成威胁。




图 2-6 连接故障的诱因及后果

2.4 锂离子电池测试平台及故障实验方案

基于上述对故障分析可知，电池发生故障时内部特征难以测量，只能通过电池的电气特征进行后续故障处理，且本文是基于数据驱动进行故障诊断，所以收集精确且可靠的数据是极其重要的。因此，本章根据故障的特性分析搭建单故障测试平台和多故障测试平台，以确保实验数据的真实性和可靠性。

2.4.1 测试平台

电池组故障实验平台如图 2-7 所示，主要由上位机、电池组、电池组测试系统和高低温实验箱 4 个部分组成。




图 2-7 电池组实验平台

其中，电池组测试系统采用深圳亚科源公司生产的 60V-100A-4 通道的充放电测试系统。该系统支持 4 个通道单独操作，单通道的电压测量范围为 5~60V，电流的测量范围为 0~100A，整机最大功率为 24kW。另外电压和电流的测量精度分别为 5mV 和 100mA，最小采样周期为 10ms，并且该系统具备循环嵌套功能，最大支持 3 层嵌套。表 2-2 为 60V-100A-4 通道电池组测试系统的详细技术参数。

表 2-2 60-100A-4 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	5~60V
	充放电电流范围	0~100A
	测量精度/稳定度	$\pm 0.1\%FS/\pm 0.1\%FS$
	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、直流内阻测试以及循环测试等	

高低温实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°C 到 150°C ，温度波动度在 $\pm 0.3^{\circ}\text{C}$ 。高低温实验箱的详细技术参数如表 2-3 所示。

表 2-3 高低温实验箱的技术参数

项目	参数	指标项目	参数值
型号	YKYTECH-408L	温度分辨率	0.1°C
尺寸	1050*1650*1950(mm)	温度均匀度	$\leq \pm 2^{\circ}\text{C}$
电源	AC380V/50Hz	温度波动度	$\leq \pm 0.3^{\circ}\text{C}$
额定功率	8.5kW	温度范围	$-10^{\circ}\text{C}\sim 150^{\circ}\text{C}$

故障实验电池为国内某厂家生产的磷酸铁锂电池，其额定容量为 40Ah，额定电压为 3.7V，其它规格参数如表 2-4 所示。

表 2-4 测试锂电池的规格参数

名称	参数
电池类型	磷酸铁锂电池
额定电压	3.7V
额定容量	40Ah
充电截止电压	4.2V
放电截止电压	2.7V
体积	27mm*92mm*148mm
重量	0.7kg

2.4.2 单故障实验方案

通过上述的电动汽车故障分析可得，在锂离子电池常见的故障中，短路故障引起的事故最多，且危险性最高。短路故障早期时电池电压变化不明显，导

致难以及时诊断，但随着电池的不断运行，电池温度不断上升，电压持续上升，电流也在不断下降，如果没有在早期及时诊断短路故障，可能会引发更加严重的安全事故，因此，本文将单故障的诊断对象定为早期的外短路故障。另外，基于数据驱动的故障诊断方法的基础是准确的数据，没有准确的数据会对后续诊断模型造成一定的误差。因此，本章利用已搭建的电池组测试平台，设计了一套短路故障实验方案，目的是获取电动汽车在实际运行工况下遇到外短路故障的电压变化数据。模拟外短路故障实验步骤如下：

(1) 选取四节电池串联而成的电池组，然后将其放入高低温实验箱中，并将温度设置为 25°C 。

(2) 将电池组用 1C 的恒流恒压方式进行充电，当电池组中任意一节单体电池充电至截止电压时停止充电。

(3) 充满电后，将电池组静置 1 小时，以确保每节电池电压稳定和电池的温度下降。

(4) 静置结束后，在动态应力测试（Dynamic Stress Test, DST）工况下对电池组进行充放电实验，其 DST 工况电流如图 2-8 所示。




图 2-8 DST 工况电流图

(5) 短路实验开始时为正常运行，当运行到一定时刻后注入故障。其中，短路故障是由短路电阻和开关模拟而来，通过控制开关来控制短路故障的注入，具体短路故障模拟图如图 2-9 所示。然后故障持续时间为 60s ，再打开开关，恢复电池组正常运行状态。短路故障中的短路电阻本文起始设置为 2.5Ω 和 5Ω 。




图 2-9 短路故障模拟图

2.4.3 多故障实验方案

除了单一故障诊断，多故障分类也极其重要，如果确定故障后，对故障的种类不清楚，会对后续维修造成一定的影响。再从上述常见的故障分析可得，过充/过放发生时，电池电压会超过最大充电电压或者低于最大放电电压。而短路故障和连接故障在早期时，电池电压是在电池正常运行范围内的，进而导致故障难以诊断。因此，本文将故障诊断研究对象定为短路故障和连接故障。在同一工况下，每种故障电压数据都和正常状态时的数据有着一定的联系，这将导致故障之间以及故障和正常状态之间难以区分。所以本章基于上述实验平台设计一份多故障实验方案，具体实验方案如下：

(1) 将 8 个电池分为两组，每一组都是由 4 个电池串联而成的电池组，再将电池组置于温控箱中，并将温度设置为 25°C 。后续步骤与上述短路故障实验方案一致。

(2) 静置环节结束后，将两组电池组分别在城市道路循环（Urban Dynamometer Driving Schedule, UDDS）和新欧洲驾驶循环（New European Driving Cycle, NEDC）工况下进行充放电实验。其中，UDDS 和 NEDC 工况电流如图 2-10 所示。




图 2-10 UDDS 和 NEDC 工况电流图

(3) 在实验开始时注入故障，故障分别为短路故障和连接故障，其中连接故障是通过在两个电池之间串联电阻和开关而成，具体的连接故障模拟如图 2-11 所示。然后在 UDDS 和 NEDC 工况下分别运行正常、短路故障和连接故障三种状态，并且在每种状态下电池组运行四次，单次运行时间为两次工况循环。其中，连接故障中的故障电阻为 0.1Ω 。




图 2-11 连接故障模拟图

2.5 实验数据获取及其预处理

2.5.1 移动平均滤波法

经过上述实验后，本章采用移动平均滤波法对获取的实验数据进行去噪。移动平均滤波法是一种简单的信号滤波算法，主要用于减小信号中的噪声或者去除高频成分，从而平滑信号。它基于对信号中一定窗口内数据的平均值进行计算，其基本原理为：一个含有 N 个样本的数据集 $X(n)$ ，其中 n 是样本的索引，范围为 $(0-N-1)$ ，移动平均滤波法是在利用一个大小为 M 的窗口在数据集上滑

动，然后通过计算窗口内的平均值进行去噪。

对于滑动窗口的每个位置 k ，去噪后的输出 $y(k)$ 可以通过以下公式计算：

$$y(k) = \frac{X(k) + X(k-1) + X(k-2) + \dots + X(k-M+1)}{M} \quad (2-4)$$

上式中， $X(k)$ 是信号序列中索引为 k 的样本值， $1/M$ 是归一化因子，用于平均化窗口内的样本值。

移动平均滤波法的核心思想是利用窗口内多个样本的平均值来代表当前样本值，从而减小随机噪声或者高频成分对信号的影响，滑动窗口的大小决定了平滑的程度，较大的窗口可以有效地平滑信号，但可能会导致滞后响应，较小的窗口可以更快地响应信号的变化，但平滑效果可能较差，因此选择一个大小合适的窗口是极其重要的^[74]。

2.5.2 单故障数据获取及其预处理

本文单故障的研究对象为短路故障，由上述的短路故障实验平台获取数据，具体数据如图 2-12 所示。图（a）是短路电阻阻值为 2.5Ω 的电压原始数据，图（b）是短路电阻阻值为 5Ω 的电压原始数据。




图 2-12 单故障电压原始数据

由于电压测量过程中存在的测量噪声，导致数据有着一定的变化，这些细小的变化可能会导致后续故障不能及时诊断，因此采用移动平均滤波法对其进行去噪，并将滑动窗口的大小设定为 5，具体结果如图 2-13 所示。图（a）是短路电阻阻值为 2.5Ω 的电压数据对比图；图（b）是短路电阻阻值为 5Ω 的电压数据对比图。





图 2-13 单故障电池电压对比图

2.5.3 多故障数据获取及其预处理

除了获取单故障的实验数据，本章也通过多故障实验平台获取了多故障实验数据，它们分别为在 UDDS 和 NEDC 工况下电池组正常运行、短路故障和连接故障三种状态的电压原始数据，具体如图 2-14 所示。






图 2-14 多故障电压原始数据

在图 2-14 中，图 (a)、图 (b) 和图 (c) 分别为 UDDS 工况下的连接故障、短路故障和正常状态的电压原始数据；图 (d)、图 (e) 和图 (f) 分别为 NEDC 工况下的连接故障、短路故障和正常状态的电压原始数据。原始数据中由于测量噪声的存在，会对后续特征提取和故障诊断造成一定影响。因此，本文也采用移动平均滤波法对多故障实验数据进行去噪，移动窗口大小为 5，最后数据对比图如图 2-15 所示。图 2-15 中，图 (a) 为 UDDS 工况下的电压原始数据和去噪后数据的对比图；图 (b) 为 NEDC 工况下的电压原始数据和去噪后数据的对比图。




图 2-15 多故障电池电压对比图

2.6 本章小结

在本章中，首先介绍了锂离子电池的基本结构以及工作原理，还介绍了不

同正极材料电池之间的区别，为后续实验电池的选择提供参考。然后，对锂离子电池常见的故障进行特性和演化过程分析，以此为后续故障诊断提供基础。接着，介绍了实验室的电池组测试平台，并基于此设计了单故障和多故障实验方案，并记录相关数据。最后，对采集的原始数据进行分析，并利用移动平均滤波法对其进行去噪，为后面章节提出的单故障诊断方法和多故障分类方法的有效性和鲁棒性提供数据支撑。

第 3 章 基于 Pearson 相关系数和 KPCA 的电池组早期短路故障诊断方法

3.1 引言

电动汽车采用锂离子电池作为动力源，但其潜在的安全风险不容忽视。通过第 2 章的故障分析可知，在电池的多种故障中，短路故障所带来的危险性最大，且短路故障早期具有一定的隐蔽性，所以基于传统阈值的故障诊断方法难以诊断。因此，论文提出了一种基于 Pearson 相关系数和核主成分分析（KPCA）的电池组微短路故障诊断方法。首先，测量各电池在不同运行状态下的电压值，并使用移动滤波方法进行去噪，计算同一串联分支中各电池电压之间的 Pearson 相关系数，形成数据集。其次，利用 Pearson 相关系数数据集训练 KPCA 算法，通过计算平方预测误差（Squared Prediction Error, SPE）统计量获得控制阈值。训练过程完成后，计算电池实时电压值的 Pearson 相关系数，并计算相应的平方预测误差统计量，以确定是否超过阈值，如果超过阈值，则绘制贡献图。最后，根据贡献图中贡献率的特点，交叉定位故障电池。基于短路故障实验获取数据的实验结果，相比于其它输入特征、算法，该方法能够在故障发生时立即进行诊断，且贡献率特征相较于其他方法更为明显，有利于故障定位。

3.2 方法与原理

3.2.1 相关系数原理

本章采用的输入特征是相关系数，常用的相关系数有 Pearson 相关系数、Spearman 相关系数和 Kendall 相关系数。Pearson 相关系数主要适用于分析连续型数据，并建立在两个变量各自遵循正态分布且各自的标准差不为零的假设之上。它与变量之间的协方差和标准差有关，其值等于协方差和标准差的比值，以此来将两个变量之间的相关性用一个值表示。值得注意的是，皮尔逊相关系数对异常值（或极端数据点）具有较高的敏感性。Pearson 相关系数的计算公式为

$$P_{xy} = \frac{Cov(x,y)}{\sqrt{Var(x)} \times \sqrt{Var(y)}} \quad (3-1)$$

上式中, $Cov(x,y)$ 为两个变量 x 和 y 的协方差, $Var(x)$ 和 $Var(y)$ 分别为 x 和 y 的方差。

Spearman 相关系数是一种用于评估两个变量间关联性的非参数统计方法,其核心在于通过比较变量的排序位次而非原始数据值来度量它们的变化趋势及其一致性强度。该方法将观测值转换为秩次后进行统计分析,从而得出变量间的相关性程度。**Spearman** 相关系数的计算公式为

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

上式中, d 为两个变量的位次值之差, N 为两个变量的数据长度。

Kendall 相关系数则是通过比较数据之间的排序关系来计算的。假设有两个变量 X 和 Y , 每个变量有 n 个观测值, 对这些观测值的排序中, **Kendall** 相关系数的计算基于每一对观测值之间的“协同”或“不协同”。**Kendall** 相关系数具体的计算公式为

$$K_{xy} = \frac{C - D}{\frac{n(n-1)}{2}} \quad (3-3)$$

上式中, C 是观测值一致的数量, D 是观测值不一致的数量, n 是观测值的数量。

3.2.2 KPCA 故障诊断原理

KPCA 是一种非线性数据分析方法, 其基本思想如图 3-1 所示, 即首先通过非线性映射函数将原始数据转换到高维空间, 然后将非线性问题转化为线性问题, 最后在高维空间中使用主成分对数据进行分析^[75]。




图 3-1 KPCA 原理图

本章假设输入数据为 $X \in R^m$ ，和 $X = [x^{(1)}, x^{(2)}, \dots, x^{(n)}]^T \in R^{n \times m}$ 。其中， n 表示样本总数， m 表示变量个数。KPCA 采用一个非线性映射函数（记为 Φ ）将输入数据转换到一个高维特征空间，该空间的协方差矩阵为

$$C = \frac{1}{n-1} \Phi^T(X) \Phi(X) \quad (3-4)$$

上式中，设 C 的特征值为 λ_i 和特征向量为 V_i ，且 $i=1, 2, 3, \dots, n$ ，则有

$$V_i = \Phi^T(X) a_i \quad (3-5)$$

上式中， a_i 为线性相关系数。引入核矩阵 $K = \Phi(X) \Phi^T(X)$ ，并对其进行中心化处理，其公式为

$$\bar{K} = K - IK - KI + IKI \quad (3-6)$$

上式中， I 是一个有系数的单位矩阵，且在后文中， $\bar{K}$ 仍用 K 代替。将式（3-5）代入式（3-4）可得

$$\lambda_i a_i = \frac{1}{n-1} K a_i \quad (3-7)$$

对于第 l th 个样本，其核成分表示为

$$t_i(l) = \Phi^T(x^{(l)}) V_i = \Phi^T(x^{(l)}) \Phi^T(X) a_i = k_l^T a_i \quad (3-8)$$

上式中， $k_l^T = [k(x^{(l)}, x^{(1)}), k(x^{(l)}, x^{(2)}), \dots, k(x^{(l)}, x^{(n)})] \in R^{1 \times n}$ 是对应的核向量。

常见的核函数有多项式核函数、Sigmoid 核函数和高斯核函数（Radial Basis Function, RBF）。其中，RBF 核函数应用广泛且效果较好，所以本章核函数选用 RBF 核函数。

在进行 KPCA 算法开始时，最关键的是主成分数量的确定，其可以根据特征值的累积方差贡献率可得，具体计算式为

$$CPV = \frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^m \lambda_i} \quad (3-9)$$

上式中， p 是主成分中在高维特征空间剩余的维数。在本章中，将 CPV 设置为 0.65，超过这一阈值的维数，即为本章所选用的主成分数量。

核成分被累积方差贡献率 CPV 分成主成分和残差成分两个部分，其中主成分和残差成分可以构成 Hotelling- T^2 (T^2) 和 SPE 统计量进行故障诊断。本章选用 SPE 统计量进行故障诊断，其计算公式为

$$SPE(l) = \sum_{i=1}^n t_i^2(l) - \sum_{j=1}^p t_j^2(l) \quad (3-10)$$

根据上述公式算出训练数据的 SPE 统计量，然后确定 SPE 统计量的控制阈值，其计算公式为

$$SPE_{\alpha} = \theta_1 \left[\frac{C_{\alpha} \sqrt{2\theta_2 h_0}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{-h_0} \quad (3-11)$$

上式中， $\theta_i = \sum_{j=p+1}^m \lambda_j^i (i=1,2,3)$ ， $h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2}$ ， C_{α} 为标准正态分布下的置信极限。

当数据出现异常时， $SPE > SPE_{\alpha}$ 。

数据出现异常，即电池组出现故障，然后计算输入变量对 SPE 统计量异常的贡献率。最后，根据贡献率绘制贡献图，通过看贡献图上贡献率最大的两个变量来定位故障电池。贡献率背后的理念时将统计变量视为多元函数，其中因变量是统计变量，自变量是多元状态数据。贡献率的具体计算公式为

$$f = f(x_1, x_2, \dots, x_m) \quad (3-12)$$

上式中， f 是变量 x 的函数。然后，根据拉格朗日中值定理可得

$$\begin{aligned}
 & f(x_1, x_2, \dots, x_m) - f(x_{10}, x_{20}, \dots, x_{m0}) \\
 &= [(x_1 - x_{10}) \frac{\partial}{\partial x_1} + \dots + (x_m - x_{m0}) \frac{\partial}{\partial x_m}] \\
 & f[x_{10} + \theta(x_1 - x_{10}), \dots, x_{m0} + \theta(x_m - x_{m0})] \quad (0 < \theta < 1)
 \end{aligned} \tag{3-13}$$

令 $x_{10} = x_{20} = \dots = x_{m0} = 0$ ，然后 $f(x_{10}, x_{20}, \dots, x_{m0}) = 0$ ，则式 (3-13) 变为

$$f(x_1, x_2, \dots, x_m) = (x_1 \frac{\partial}{\partial x_1} + \dots + x_m \frac{\partial}{\partial x_m}) f(\theta x_1, \dots, \theta x_m) \tag{3-14}$$

由式 (3-9) 可得，每个 SPE 统计量都可以分解成每个输入变量的和，然后这些导数等效成是变量对 SPE 统计量的贡献率，所以变量的贡献率计算公式为

$$C_f(x_j) = x_j \frac{\partial}{\partial x_j} f(\theta x_1, \dots, \theta x_m) \tag{3-15}$$

最后，根据式 (3-9) 和式 (3-11) 可得，SPE 统计量的贡献率函数为

$$\begin{aligned}
 C_SPE(x_j^{(h)}) &= x_j^{(h)} \left(\frac{\partial k(x^{(h)}, x^{(h)})}{\partial x_j^{(h)}} - \right. \\
 & \left. 2 \left[\frac{\partial k(\theta x^{(h)}, x^{(h)})}{\partial x_j^{(h)}}, \dots, \frac{\partial k(\theta x^{(h)}, x^{(i)})}{\partial x_j^{(h)}} \right] \alpha_s \alpha_s^T k_h \right) \Big|_{\theta x^{(h)}}
 \end{aligned} \tag{3-16}$$

上式中，

$$\begin{aligned}
 \frac{\partial k(\theta x^{(h)}, x^{(i)})}{\partial x_j^{(h)}} &= -\frac{1}{\gamma} 2\theta(\theta x_j^{(h)} - x_j^{(i)}) \exp(-\theta x^{(h)} - x^{(i)2} / \gamma) \\
 &+ \frac{1}{n} \sum_{l=1}^n \frac{1}{\gamma} 2\theta(\theta x_j^{(h)} - x_j^{(l)}) \exp(-\theta x^{(h)} - x^{(i)2} / \gamma)
 \end{aligned} \tag{3-17}$$

$$\frac{\partial k(x^{(h)}, x^{(h)})}{\partial x_j^{(h)}} = \frac{2}{n} \sum_{l=1}^n \frac{1}{\gamma} 2(x_j^{(h)} - x_j^{(l)}) \exp(-x^{(h)} - x^{(l)2} / \gamma) \tag{3-18}$$

上式中， θ 是从训练数据中得出的。

贡献率的正负是对故障定位没有影响的，因此，以便更容易地实现故障定位，本章构建了一个相对贡献率，其计算公式为

$$C_SPE_d = \left| \frac{C_SPE - \text{mean}(C_SPE)}{\text{mean}(C_SPE)} \right| \tag{3-19}$$

图 3-2 为 KPCA 算法的主要流程，其中重点在于核函数的选择以及主成分数量的确定。根据经验，本章选用高斯核函数，随后通过训练多组数据来确定

RBF 核宽度的参数 S ，并将其设定为 0.5。主成分的数量基于 CPV 来确定，因为电池组在相同的工况条件下运行，导致电压具有一定的相似性，所以主成分的数量设为 1。CPV 通过特征值的累计贡献率阈值来选择主成分的数量，本章中将此阈值设定为 0.65。即当两个特征值的累积方差贡献率之和大于 0.65 时，确定主成分的数量，然后进行一步计算。




图 3-2 KPCA 算法流程图

3.2.3 基于 Pearson 相关系数和 KPCA 的电池组故障诊断流程

在电池组故障诊断模型中，Pearson 相关系数作为 KPCA 模型的输入，通过后续 SPE 统计量是否超过控制阈值，来确定是否有故障发生，然后再利用贡献图来对故障电池进行定位。电池组故障诊断的具体流程如图 3-3 所示，诊断流程如下：

步骤 1：数据采集与去噪。首先，采集串联电池组中每个电池的电压，然后使用移动滤波方法对数据进行去噪，本章中滤波窗口大小选为 5。

步骤 2：特征提取。在特征提取阶段，确定滑动窗口的大小，并在滑动窗口内计算相邻电池电压之间的 Pearson 相关系数，本章中滑动窗口的大小设置为 100。最后，还计算了第一个和最后一个电池电压之间的 Pearson 相关系数，并

将其作为诊断模型的输入，用于故障表征。

步骤 3：离线建模。选择正常运行时的 Pearson 相关系数作为输入特征，确定核函数参数和主成分数量，然后将 Pearson 相关系数输入到 KPCA 算法中，计算 SPE 统计量控制阈值。

步骤 4：在线故障诊断。实时采集电池电压数据并进行特征提取，将特征输入到 KPCA 模型中，计算 SPE 统计量并与阈值进行比较，如果超出阈值，则发生故障，反之，则未发生故障。

步骤 5：故障电池定位。在确定发生故障后，计算每个输入变量对 SPE 统计量的贡献率，然后绘制贡献图，并根据贡献图中贡献率最大的两个变量来确定故障电池。例如，计算出电池 1 和电池 2 之间的相关系数为 1，电池 2 和电池 3 之间的相关系数为 2。如果相关系数 1 和 2 的贡献率最大，则确定故障电池为电池 2。




图 3-3 电池组故障诊断流程图

3.3 实验验证及分析

3.3.1 数据分析与特征提取

本章采用的数据来自短路故障实验，如图 3-4 所示，这是在 DST 工况下电

池组运行时的电压数据，该数据已经过移动滤波法去噪。由于充电/放电电流大小相同，电压数值的波动趋势也相同。在本章中，我们为第 4 号电池设置了短路故障，采用了不同阻值的短路电阻，阻值分别为 2.5Ω 和 5Ω ，故障设置在 DST 操作条件开始后 996 秒，故障持续时间约为 60 秒，当短路故障消除后，电池电压恢复正常。从图 3-4 中可以明显看出，由于本研究中采用的短路电阻阻值较大，第 4 号电池的电压变化极小。因此，使用传统的基于阈值的方法检测故障变得具有挑战性。此外，随着电池继续运行，短路电阻的阻值可能会逐渐减小，进而会引发热失控等事故。




图 3-4 去噪后电压图

采用上述电压数据作为初始数据集，然后采用大小为 100 的滑动窗口来计算选定数据集的 Pearson、Kendall 和 Spearman 相关系数。其中，相关系数是基于相邻电池之间的电压进行计算的，本章设第一块电池和最后一块电池也被视为相邻电池。具体结果如图 3-5 所示。图中显示，前 800 组数据代表正常运行状态，而后 200 组数据包含故障。因此，本章选择前 800 组数据作为训练数据集，后 200 组数据作为测试数据集。




图 3-5 不同阻值短路电阻的三种相关系数图

3.3.2 故障诊断模型性能测试

为了验证上述方法的先进性，本章将 KPCA 算法与主成分分析（Principal Component Analysis, PCA）算法进行对比，并且采用 Pearson 相关系数作为输入特征。通过上述的数据可得，故障从第 96 个采样点开始注入，所以计算相关系数后，第 96 个采样点之后的所有数据均为故障数据。对比结果如图 3-6 所示，

从图 3-6 中可以看出，KPCA 和 PCA 算法的诊断时间都准确，但两种方法的贡献图不一样。本章设定故障电池为 4 号电池，因此 3 号电池与 4 号电池之间的相关系数以及 1 号电池与 4 号电池之间的相关系数发生了变化，导致贡献图中变量 3 和变量 4 的贡献率最高。采用 Pearson 相关系数结合 KPCA 的模型正确地绘制了贡献图，且结果明显；而采用 Pearson 相关系数结合 PCA 的模型则错误地绘制了贡献图，即贡献率计算不准确，这可能导致故障电池定位不准确。因此，本章提出的方法具有一定的先进性。




图 3-6 KPCA 和 PCA 算法对比图

上述对比验证了 KPCA 算法的有效性，接下来继续验证 Pearson 相关系数作为输入特征的有效性。本章采用三种相关系数作为输入特征进行对比，而且为了验证相关系数作为输入特征的鲁棒性，采用不同短路电阻阻值的数据进行验证，具体的诊断结果如图 3-7 所示。




图 3-7 不同短路电阻阻值下三种相关系数的诊断结果图。(a)(b)Pearson 相关系数，
(c)(d)Kendall 相关系数，(e)(f)Spearman 相关系数

从图 3-7 可以看出，这是 2.5Ω 和 5Ω 短路电阻下，三种相关系数加上 KPCA 模型的诊断结果图。对于这三种相关系数，其诊断结果各不相同。接着，从表 3-1 可以看出，这是诊断时刻，即模型诊断出故障的时刻。在本章中，注入故障

的时刻是第 96 个样本点，因此诊断时刻越接近第 96 个样本点，诊断效果越好。在不同短路电阻下，Pearson 相关系数加上 KPCA 模型的诊断时刻都是第 96 个样本点；而在 5Ω 短路电阻下，Kendall 相关系数加上 KPCA 模型的诊断时刻是第 104 个样本点；在 2.5Ω 短路电阻下，KPCA 模型的诊断时刻是第 99 个样本点。对于 2.5Ω 短路电阻，Spearman 相关系数加上 KPCA 模型的诊断时刻是第 101 个样本点，而在 5Ω 短路电阻下，其诊断时刻是第 128 个样本点。综上所述，本章提出的方法诊断效果最好，能够及时诊断出故障，即使在短路电阻阻值较大的情况下也能及时诊断出故障，而其他两种方法虽然能够诊断出故障，但在不同短路电阻下无法及时诊断出故障，因此本章提出的方法具有一定的优越性和鲁棒性。

表 3-1 故障诊断时刻表

相关系数	5Ω 短路电阻故障诊断时刻	2.5Ω 短路电阻故障诊断时刻
Pearson	第 96 个样本点	第 96 个样本点
Kendall	第 104 个样本点	第 99 个样本点
Spearman	第 128 个样本点	第 101 个样本点

经过上述故障诊断后，确定发生了故障。接着进行故障电池的定位，计算每个输入变量对 SPE 统计量的贡献率，并将贡献率来绘制贡献图。具体细节如图 3-8 所示，且三种相关系数作为输入特征的贡献图都能准确定位故障电池。从图 3-8 中可以看出，特征 3 和 4 的贡献率最大，即电池 3 的电压与电池 4 的电压之间的相关系数，以及电池 1 的电压与电池 4 的电压之间的相关系数存在异常，且这两个相关系数都与电池 4 有关，因此确定电池 4 为故障电池。




图 3-8 诊断模型贡献图

通过上述对比实验，结果显示本章提出的方法具有一定的先进性。接着，为了进一步验证该方法的鲁棒性，我们又分别在 40°C 和 10°C 的条件下进行了短路实验。实验中选用的电池规格相同但老化程度不同，短路电阻阻值约为 10Ω 。故障注入时间分别为第 1001 秒和第 1000 秒，出现故障的电池为 2 号电池。具体电池电压变化情况如图 3-9 所示。





图 3-9 不同温度下电池组电压图

经过移动滤波对电压进行去噪处理后，计算相邻单体电池电压之间的 Pearson 相关系数，并将其输入到 KPCA 故障诊断模型中，具体的诊断结果如图 3-10 所示。






图 3-10 不同温度下模型的故障诊断图和贡献图

由于本实验中所用的短路电阻非常大，且电池间存在一定的不一致性，因此短路故障对电池的影响微乎其微，仅仅导致电压波动约 0.002V 左右，但这非常符合电池在微短路故障早期的表现。再次观察上述图表，可以看出该方法在 40°C 下的诊断结果是第 108 个采样点出现故障，在 10°C 下，该方法的诊断结果是第 107 个采样点出现故障，与本章注入故障时间相差不大。最后，从上述贡献图可以看出，变量 1 和变量 2 的贡献最大，即电池 1 与电池 2 之间的相关系数以及电池 2 与电池 3 之间的相关系数出现异常，所以电池 2 为故障电池，这与本实验中设置的故障电池一致。因此，本章提出的方法能够在不同温度、不同老化程度以及较大的短路电阻条件下，在短时间内诊断出故障，并准确定位故障电池。

3.4 本章小结

本章基于 Pearson 相关系数和 KPCA 构建了一个短路故障诊断模型，该模型利用电池组在发生早期微短路故障时电压的微小波动，解决了传统阈值方法无法检测早期故障中电压的异常变化且无法定位故障电池的问题。模型首先利用 Pearson 相关系数放大故障电池的电压微小波动，然后利用 KPCA 算法对电池组进行故障诊断并定位故障电池。通过实验验证，KPCA 算法比 PCA 算法在故障定位方面更为准确。接着，将该模型与使用 Kendall 相关系数和 Spearman 相关系数作为输入特征的模型进行了比较。基于 Pearson 相关系数的诊断时间与故障注入时间一致，而基于其他两种相关系数的诊断时间晚于故障注入时间。最

后，通过不同温度、不均匀老化和较大短路电阻故障的实验验证，该模型仍能在短时间内诊断出故障。因此，本章提出的算法能够有效检测电池的早期微短路故障，并对故障电池进行定位，从而提高电池的安全性和延长其使用寿命。

第 4 章 基于电压极差和 LSTM 的电池组多故障诊断方法

4.1 引言

上一章的研究对象是短路故障，即只是对单个故障进行诊断，并不能区分多故障。因此，本章提出了一种基于电压极差和长短期记忆网络（LSTM）的电池组多故障分类诊断的方法。首先，采用移动滤波法对电池组的原始电压数据进行去噪，然后计算电池组的电压极差，并利用移动窗口法去提取一定长度的电压极差作为特征。其次，将特征输入到 LSTM 模型中，通过分类结果确定是否有故障发生。最后，如果确定故障发生及故障类型，就利用一定特征长度内的最大/最小电压电池号的变化图确定故障电池的位置。实验验证是在城市循环工况（UDDS）和新欧洲驾驶循环（NEDC）测试下进行的，并且在训练和测试同一工况数据以及训练和测试不同工况数据的情况下，与 CNN、BP 和 SVM 三种算法进行对比。实验结果表明，本章提出的诊断模型具有较高的准确率，并且其可以实现不同工况数据之间相互迁移学习，具有较高的泛化性。

4.2 方法与原理

4.2.1 电压极差定义

电压是电池组运行时可直接测量和获取的数据，且电压极差是电压的一个重要指标，电池组电压极差反映了组内电池运行状态的差异，是评估电池组一致性的重要指标，其计算公式为

$$\Delta U = U_{\max} - U_{\min} \quad (4-1)$$

上式中， $U_{\max}$ 是电池组中单体电池电压最大值， $U_{\min}$ 是电池组中单体电池电压最小值。

4.2.2 LSTM 算法原理

LSTM 算法是一种适合处理和预测时间序列数据的循环神经网络，它在处理数据多分类时也表现出色，所以本章将其作为故障分类的算法。LSTM 网络是基于 RNN 的基础上改进而来，RNN 网络结构如图 4-1 所示，其主要由输入层、隐藏层和输出层构成，图中 X 为输入序列，S 为隐藏状态，O 为输出序列^[76]。

从图 4-1 中还可以看出，在 t 时刻的隐藏状态 S_t 不仅取决于当前时刻输入 X_t 还取决于 $t-1$ 时刻的隐藏状态 S_{t-1} 。因此，RNN 网络具有一定的短时记忆功能。




图 4-1 RNN 模型结构图

传统的 RNN 网络的不足之处在于，其网络训练过程中双曲正切(tanh)激活函数使用会使后面时刻的梯度值降为 0，进而发生梯度消失或者梯度爆炸等现象，从而使 RNN 网络对于时间序列信号特征的记忆性减弱，最终影响其对于长时间序列特征的训练结果^[77]。LSTM 网络就是基于这个问题在 RNN 网络结构上增加了记忆存储单元，具体网络结构如图 4-2 所示。图中，隐藏状态 S_t 不仅和 S_{t-1} 、 X_t 有关，还和当前时刻的存储单元 L_t 有关。隐藏状态 S 和存储单元之间是一种相互影响的关系，其中，上一时刻的 S_{t-1} 和当前时刻的 X_t 通过 sigmoid 函数和 tanh 函数可以对存储单元 L_{t-1} 的内容进行删除或者增加新的存储单元 L_t ， L_t 除了继续往下传递之外，还可以用来更新 S_t 。LSTM 网络的本质是同时保持了短时记忆链 S_t 和长时记忆链 L_t ，并且互相更新。




图 4-2 LSTM 模型结构图




图 4-3 LSTM 单元结构图

LSTM 内部单元是由遗忘门、输入门和输出门组成，具体如图 4-3 所示。图中，第一部分为遗忘门，根据前一时刻的隐藏状态 S_{t-1} 与当前时刻输入 X_t 进行 sigmoid 函数运算，其具体公式为

$$f_1 = \text{sigmoid}(w_1[S_{t-1}, X_t]' + b_1) \quad (4-2)$$

上式中， w_1 为权重， b_1 为偏置向量， f_1 的输出范围为 $[0,1]$ 。将 f_1 和上一时刻的存储单元 L_{t-1} 相乘之后，可以对存储单元里面的内容进行选择性删减。

图 4-3 中第二个部分为输入门，其根据前一时刻的隐藏状态 S_{t-1} 和当前时刻输入状态 X_t 进行 sigmoid 函数和 tanh 函数运算，具体公式为

$$f_2 = \text{sigmoid}(w_2[S_{t-1}, X_t]' + b_2) * \tanh(\hat{w}_2[S_{t-1}, X_t]' + \hat{b}_2) \quad (4-3)$$

上式中， $\tanh$ 函数的取值范围为 $[-1,1]$ ，其对数据进行梳理和归纳。将 f_2 和删减后的存储单元 L_{t-1} 相加后，即可增添新内容，具体表示为

$$L_t = f_1 * L_{t-1} + f_2 \quad (4-4)$$

上式中 L_t 由 S_{t-1} 通过遗忘门和输入门得到，其实现了短时记忆链对长时记忆链的更新。

图 4-3 中第三部分为输出门，不但通过 sigmoid 函数将 O_t 输出，而且还用 O_t 和 L_t 去计算 S_t ，实现长时记忆链对短时记忆链的更新，其具体表达式为

$$O_t = \sigma(w_0[S_{t-1}, X_t]' + b_0) \quad (4-5)$$

$$S_t = O_t \tanh(L_t) \quad (4-6)$$

上式中， $\tanh$ 激活函数和 Sigmoid 激活函数的公式分别为

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (4-7)$$

$$\sigma(z) = \frac{1}{1 + e^{-z}} = \frac{1 + \tanh(\frac{z}{2})}{2} \quad (4-8)$$

综上所述，LSTM 单元凭借其独特的遗忘门、输入门和输出门结构，实现了长短时记忆的有效更新与交互。相较于传统的 RNN，LSTM 网络在提取序列信号特征方面展现出更高的精确性，进而能够实现更高的识别准确率和更优的分类性能。

4.2.3 LSTM 多故障分类模型

本章的故障分类诊断模型为 LSTM 神经网络分类模型，其主要由输入层、LSTM 层、Relu 激活层、Dropout 层、全连接层、Softmax 层和输出分类层构成，具体流程如图 4-4 所示。首先，输入数据为提取的电压极差，特征长度为 200，特征维度为 1，将电压极差进行归一化后输入到模型的输入层中；其次，数据再经过含有 100 个神经元的 LSTM 层的计算后，然后再输入到 Relu 激活层，并将其计算结果输入到 Dropout 层进行 20% 的随机丢弃，防止过拟合；再次，将其分类结果输入到全连接层，全连接层的输出单元为 3；最后，由 Softmax 激活函数处理全连接层的输出结果，将其结果输出为 1、2 和 3，即正常状态、连接故障和短路故障。




图 4-4 LSTM 多故障分类流程图

4.2.4 基于电压极差和 LSTM 的电池组多故障分类诊断模型

根据正常、短路故障和连接故障三种状态时的电压变化，本章提出了一种

基于电压极差和 LSTM 算法的电池组多故障分类诊断模型，该模型的输入特征为电压极差，诊断算法为 LSTM，具体分类诊断流程如图 4-5 所示。




图 4-5 电池组多故障分类诊断流程图

从图 4-5 中可以看出，本章提出的多故障分类诊断方法主要分为以下几个步骤：

步骤 1：数据采集与去噪。首先，采集串联电池组在不同工况下不同状态时的各个单体电压，然后采用移动滤波法对数据进行去噪，其中滤波窗口大小选为 5。

步骤 2：特征提取。在特征提取中，先计算电池组中单体最大电压和最小电压之间的差值，然后利用移动窗口法将电压极差分成 n 个输入特征，其中，窗口大小初步选为 50-250，经过后续模型验证，窗口大小设定为 200。

步骤 3：离线建模。将上述提取的特征按照 7:3 的比例分为训练集和测试集，然后将训练集输入到 LSTM 算法中，并同时确定 LSTM 算法的参数，其中将正常状态、连接故障和短路故障的输出设为 1、2 和 3。


步骤 4：在线诊断。将上述得到的测试集作为在线数据输入，根据输出的数字确定是否故障以及确定故障类型。

步骤 5：故障电池定位。确定有故障发生后，根据故障特征中电压最大/最小电池号的变化情况确定故障电池的位置。

4.3 实验验证及分析

4.3.1 实验数据分析及特征提取

本章的研究基础是第 2 章多故障实验获取的数据，该数据主要由 UDDS 和 NEDC 两种工况下的三种电池状态数据，它们分别为正常、短路故障和连接故障三种状态。具体电压数据如图 4-6 所示，且该数据是去噪后的电压数据。






图 4-6 三种状态去噪后电压图

获取电压数据后，利用移动滤波法对其进行去噪，然后进行特征提取。本章的输入特征是电压极差，根据式（4-1）计算可得，实验数据的电压极差如图 4-7 所示。




图 4-7 电压极差图

得到上述的电压极差后，利用滑动窗口法将电压极差分为 n 个部分，然后将每个部分作为输入特征，具体操作如图 4-8 所示。其中，移动窗口的步长为 1，但窗口大小要经过后续实验对比得到最优值。另外本章将输入特征分为训练集和测试集，其比例为 7:3。




图 4-8 移动窗口法

4.3.2 模型评价指标及特征长度确定

通过上述数据预处理可得，电压极差通过移动窗口法提取特征，但移动窗口大小没有确定。因此，为了获取最优的输入特征长度，本章将输入不同长度的特征，其大小分别为 50、100、150 和 200，并通过四种算法进行对比，其评价指标为

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (4-9)$$

上式中， TP 为真正例， TN 为真负例， FP 为假正例， FN 为假负例。将该评价指标作为模型的分类准确率，其模型的训练结果如表 4-1 所示。

表 4-1 不同输入特征长度的算法准确率

工况	输入长度	LSTM	CNN	BP	SVM
UDDS	50	0.99	0.99	0.97	0.87
	100	0.99	0.99	0.98	0.88
	150	1	1	0.98	0.88
	200	1	1	0.98	0.89
NEDC	50	0.98	0.98	0.97	0.71
	100	0.99	0.99	0.99	0.75
	150	0.99	0.99	0.99	0.76
	200	1	0.99	0.99	0.77

从表 4-1 可以看出，本章采用的算法分别为 LSTM、CNN、BP 和 SVM。并且在 UDDS 工况下，随着输入特征长度的增长，四种算法的分类准确率也在上涨，然后在输入特征长度为 200 时，LSTM 和 CNN 两种算法的分类准确率达到 100%。在 NEDC 工况下，输入特征也随着长度的增加，四种算法的分类准确率

也在逐渐上涨，且在输入特征长度达到 200 时，LSTM 算法的分类准确率达到 100%，其它算法也具有很高的分类准确率。综上所述，当输入特征长度为 200，即移动窗口大小为 200 时，后续故障分类模型的准确率最大，因此，本章将移动窗口大小设定为 200。

确定输入特征长度后，为验证输入特征的有效性，本章将输入特征分别为原始电压数据和电压极差的两种模型进行对比，对比结果如表 4-2 所示。

表 4-2 不同输入特征模型的结果对比

原始电压数据	LSTM	CNN	BP	SVM
NEDC	0.6334	0.8492	0.8477	0.4811
UDDS	0.7665	0.8500	0.8149	0.5061
电压极差	LSTM	CNN	BP	SVM
NEDC	1	0.9987	0.9996	0.7796
UDDS	1	1	0.9814	0.8947

从上面表格可以看出，当输入特征为原始电压数据时，在 UDDS 和 NEDC 两种工况下，四种算法的分类准确率均不高，其中，CNN 算法的分类准确率最高，但最高仅为 85%。但当输入特征为电压极差时，在 UDDS 和 NEDC 两种工况下，四种算法的分类准确率都很高。其中，LSTM 算法在两种工况下的分类准确率均为 100%。因此，本章提出的电压极差输入特征具有一定的有效性。

4.3.3 基于 LSTM 算法的多故障分类诊断模型性能测试

确定输入特征以及输入特征大小时，并从上述表格中可以看出，在同一工况下，LSTM、CNN 和 BP 三种算法均有较高的分类准确率，因此无法体现本章采用 LSTM 算法的优越性。而且，在实际运行中，电池组运行的工况是随机的，因此我们无法获取电池实时运行的故障数据，所以我们只能用在已知工况下的运行数据进行训练，再用已知工况数据的训练后的模型去预测电池实时的运行情况。因此，本章采用两种工况相互验证，如利用 UDDS 工况下的数据训练后，去预测在 NEDC 工况下的电池组运行状态，然后再用在 NEDC 工况下的数据进行训练，并去预测在 UDDS 工况下的电池组运行状态。另外，本章还将 LSTM 算法与 CNN、BP 和 SVM 三种算法进行对比，具体结果如表 4-3 所示。

表 4-3 两种工况相互验证模型准确率

工况	LSTM	CNN	BP	SVM
UDDS-NEDC	0.809	0.628	0.729	0.494
NEDC-UDDS	0.834	0.654	0.659	0.620

从表 4-3 可以看出，在用 UDDS 工况下的数据进行训练，去预测 NEDC 工况下的电池组运行状态时，LSTM 算法的分类准确率最高，为 80.9%。然后再用 NEDC 工况下的数据进行训练，去预测 UDDS 工况下的电池组运行状态时，LSTM 算法的分类准确率也是最高，为 83.4%。

经过上述实验的验证，本章采用的 LSTM 算法相较于其它三种算法具有一定的优越性，对不同故障之间的相关信息识别更精确。LSTM 模型的分类诊断结果如图 4-9 所示。





图 4-9 LSTM 模型分类结果图与混淆矩阵图

图 4-9 中，图（a）和图（b）是在已知 UDDS 工况运行数据，去预测 NEDC 工况下电池组运行状态的情况下，它们分别为分类诊断模型真实值与预测值的对比图和混淆矩阵图；另外，图（c）和图（d）是在已知 NEDC 工况运行数据，去预测 UDDS 工况下电池组运行状态的情况下，它们也分别是预测模型真实值与预测值的对比图和混淆矩阵图。

从图（a）和图（b）中可以看出，对 UDDS 工况下的数据进行训练时，LSTM 算法可以有效的对正常状态和短路故障时的数据进行信息提取，进而对 NEDC 工况下的运行状态进行有效分类。再从图（c）和图（d）中可以看出，对 NEDC 工况下的输入数据进行训练时，LSTM 算法可以有效的对连接故障和短路故障时的数据进行有效的信息提取，使得对 UDDS 工况下电池组的运行状态进行有效分类。综上所述，在不同工况的训练数据下，LSTM 算法都能从中提取到有用的信息，从而对未知工况下电池组的运行状态进行有效分类。

4.3.4 故障定位

经过 LSTM 算法的故障诊断后，如果确定有故障发生，并且确定故障类型，下一步工作就要确定故障电池位置。本章采用的特征长度为 200，因此，当确定发生故障时，可以根据特征长度内的最大/最小电压电池号的变化情况确定故障电池位置，电池组各种运行状态下最大/最小电压电池号的变化情况如图 4-10 所示。






图 4-10 三种运行状态下电压最大/最小电池号的变化图

由图 4-10 可得，图（a）和图（b）分别是连接故障时电压最大电池号的变化图和电压最小电池号的变化图，再从图 4-10 中可以看出，电压最大电池和电压最小电池都含有 1 号电池。因此，当确定发生连接故障时，可以根据电压最大/最小电池号的变化图中同时都含有的电池号，确定其为故障电池；图（c）和图（d）分别为短路故障时电压最大电池号的变化图和最小电压电池号的变化图，从图 4-10 中可以看出，电压最小电池号的变化图中大部分都是 1 号电池。因此，当确定发生短路故障时，可以根据电压最小电池号的变化图中大部分时间都存在的电池，确定其为故障电池；图（e）和图（f）是正常状态时的电压最大/最小电池号的变化图，因为电池组单体之间的不一致性存在，导致其变化是杂乱的。综上，本章可以当确定故障后，根据最大/最小电压电池号的变化图确定故障电池的位置。

4.3.5 诊断时间

由第 2 章故障实验部分可得，数据采集的时间为 1s。因此，本章的模型诊断时间应该在 1s 之内，以便及时诊断到故障。基于 LSTM 的故障诊断模型运行时间如表 4-4 所示，从表 4-4 中看出，当用 UDDS 工况下的数据进行训练，然后去预测 NEDC 工况下的数据，模型的诊断时间为 0.18s；再当用 NEDC 工况下的数据进行训练，然后去预测 UDDS 工况下的数据，模型的诊断时间为 0.15s。总之，基于 LSTM 的模型诊断时间在允许范围内，可以及时诊断到故障。

表 4-4 模型诊断时间

LSTM	时间
UDDS-NEDC	0.18s
NEDC-UDDS	0.15s

4.4 本章小结

本章节提出了一种基于电压极差和 LSTM 的电池组多故障分类诊断方法，利用电池组不同状态之间的电压极差的差异，解决了传统方法无法实现电池组在不同工况之间相互多故障分类诊断的问题。该方法首先计算电池组的电压极差，然后通过 LSTM 算法对电池组进行多故障分类诊断，最后利用最大/最小电压电池号的变化图确定故障电池位置。通过实验验证，本章特征长度为 200 时，各模型的故障诊断率最高；然后将 LSTM 模型与 CNN、BP 和 SVM 模型比较，在训练集和测试集分别为不同工况数据时，LSTM 模型的多故障分类诊断率最高。因此，本章提出的方法可以在单一工况下训练和测试有着很高的分类准确率，然后在不同工况下训练和测试时也具有较高的分类准确率，从而说明本章节提出的多故障分类诊断模型具有一定的有效性和泛化性。

第 5 章 总结与展望

5.1 全文工作总结

锂离子电池作为电动汽车的核心部件，其安全性是极其重要，因此，故障准确诊断以及多故障分类对锂离子电池安全稳定运行有着一定的重要性。本文首先对单故障诊断进行研究，通过提取电池组电压数据的 Pearson 相关系数，并结合 KPCA 算法实现早期短路故障的诊断和故障定位。然后进一步对多故障进行研究，通过分析不同故障的特征信息，提取电池组电压数据中的电压极差，并将其作为特征输入到 LSTM 算法中，从而实现多故障分类诊断，再利用最大/最小电压电池号的变化图进行故障电池定位。上述方法分别通过基于实验平台的短路故障实验和多故障实验数据进行实验验证，实验结果证明了本文所提故障诊断模型的有效性、先进性以及鲁棒性。本文主要的研究内容和结论如下：

(1) 在详细介绍锂离子电池的结构和工作原理的基础上，分析了锂离子电池常见故障的演化过程，以此为后续研究提供理论基础和明确后续研究对象。最后，为验证本文所提出诊断模型的有效性，搭建了电池组测试平台来获取单故障和多故障实验数据，并利用移动平均滤波法对获取的数据进行去噪，以此为后续实验验证提供数据支撑。

(2) 根据上述锂离子电池常见故障分析可得，短路故障是电池所有故障中危险性最高，且早期难以检测，所以单故障的研究对象为早期的短路故障。针对早期短路故障时电压的微小波动，本文提出了一种基于 Pearson 相关系数和 KPCA 的电池组短路故障诊断模型。首先，利用 Pearson 相关系数放大故障电池的电压微小波动，然后利用核主成分分析算法对电池组进行故障诊断并定位故障电池。通过实验验证，KPCA 算法比 PCA 算法在故障定位方面更为准确。接着，将该模型与使用 Kendall 相关系数和 Spearman 相关系数作为输入特征的模型进行了比较。基于 Pearson 相关系数的诊断时间与故障注入时间一致，而基于其他两种相关系数的诊断时间晚于故障注入时间。最后，通过不同温度、不一致老化和较大短路电阻故障的实验验证，结果显示，该模型仍能在短时间内诊断出故障。因此，本文提出的算法具有一定的先进性和鲁棒性。

(3) 为了进一步对多故障进行分类诊断, 本文提出了一种基于电压极差和 LSTM 的电池组多故障分类诊断方法, 利用电池组不同状态之间的电压极差的差异, 解决了传统方法无法实现电池组在不同工况之间相互多故障分类诊断的问题。该方法首先计算电池组的电压极差, 然后通过 LSTM 算法对电池组进行多故障分类诊断, 最后利用最大/最小电压电池号的变化图确定故障电池位置。通过多故障实验数据进行实验验证, 当本文的输入特征长度为 200 时, 各模型的故障诊断率最高; 然后将 LSTM 模型与 CNN、BP 和 SVM 模型比较, 在训练集和测试集分别为不同工况数据时, LSTM 模型的多故障分类诊断率最高。因此, 本文提出方法具有一定的有效性和泛化性。

5.2 工作展望

本文针对如何提高电池组单故障诊断准确率以及多故障分类准确率开展了一定的研究工作, 所提出的基于数据驱动的单故障和多故障诊断方法, 对锂电池组的安全运行管理具有一定的参考价值。但由于受到实验设备、时间以及个人能力的约束, 在本文的基础上依然有很多工作需要优化和完善, 主要分别为以下几个方面:

(1) 本文进行的锂电池组单故障实验只进行 DST 工况下的短路故障实验, 以及多故障实验只进行 UDDS 和 NEDC 工况下的短路故障和连接故障实验, 与实际电池组运行情况有所差别。在后续研究中将考虑更多工况以及更多故障类型, 而且还得考虑电池组不一致性和环境因素, 以求更加符合实际情况, 进一步对本文提出的诊断方法进行验证分析。

(2) 本文对于电池组单故障以及多故障诊断中仅依靠电压数据, 但由于电池发生故障时内部的复杂机理, 所以在后续研究中应该考虑温度、电流以及 SOC 等相关因素的影响, 开展多种特征融合的故障诊断方法研究。

(3) 在对多故障分类诊断过程中, 本文提出的多故障分类诊断模型在不同工况之间相互验证时, 其准确率有待提高。因此, 在后续研究中将加入优化算法或者寻找分类准确率更高的算法, 以提高电池组运行时的安全性。

参考文献

- [1] VikramGoud M, Biswas P K, Sain C, et al. Advancement of electric vehicle technologies, classification of charging methodologies, and optimization strategies for sustainable development-a comprehensive review[J]. Heliyon, 2024.
- [2] 欧阳铭珂, 李坚飞, 张亚斌. 技术创新视角下中国汽车工业节能减排效率研究[J]. 中国科技论坛, 2021.
- [3] Chi J. Impacts of electric vehicles and environmental policy stringency on transport CO2 emissions[J]. Case Studies on Transport Policy, 2025, 19: 101330.
- [4] Zhang X, Cui X. Impact of cutting-edge hybrid electric vehicle technological innovation on carbon emissions in China[J]. Sustainable Futures, 2025: 100447.
- [5] 李达, 邓钧君, 张照生, 等. 电动车辆动力电池安全预警策略研究综述[J]. 汽车工程, 2023, 45(8): 1392-1407.
- [6] Tao M, Lin B, Poletti S. Deciphering the impact of electric vehicles on carbon emissions: Some insights from an extended STIRPAT framework[J]. Energy, 2025, 316: 134473.
- [7] 国务院关于印发《中国制造 2025》的通知[J]. 中华人民共和国国务院公报, 2015, 62 (16): 10–26.
- [8] 十二部委发布《绿色出行行动计划（2019-2022 年）》[J]. 人民公交, 2019, 37(8): 25–27.
- [9] 国务院办公厅关于印发新能源汽车产业发展规划(2021—2035 年)的通知[J]. 中华人民共和国国务院公报, 2020, 67(31): 16–23.
- [10] 第十三届全国人民代表大会第四次会议关于国民经济和社会发展第十四个五年规划和 2035 年远景目标纲要的决议[J]. 中华人民共和国全国人民代表大会常务委员会公报, 2021, 65(3): 428–502.
- [11] 邱艳. 基于数据驱动的车用锂离子电池故障诊断方法与应用研究[D]. 山东工商学院, 2022.
- [12] Hong J, Liang F, Yang J, et al. An exhaustive review of battery faults and diagnostic techniques for real-world electric vehicle safety[J]. Journal of Energy Storage,

2024, 99: 113234.

- [13] 洪吉超, 梁峰伟, 杨海旭, 等. 大数据驱动动力电池智能安全管理与控制方法研究[J]. 汽车工程, 2023, 45(10): 1845-1861.
- [14] 伍毅平, 杨傲然, 陈家源, 等. 基于 LightGBM 的电动汽车动力电池故障双层诊断模型[J]. 北京工业大学学报.
- [15] Yang J, Cheng F, Liu Z, et al. A novel semi-supervised fault detection and isolation method for battery system of electric vehicles[J]. Applied Energy, 2023, 349: 121650.
- [16] Sun J, Qiu Y, Shang Y, et al. A multi-fault advanced diagnosis method based on sparse data observers for lithium-ion batteries[J]. Journal of Energy Storage, 2022, 50: 104694.
- [17] Qiu Y, Sun J, Shang Y, et al. A fault diagnosis and prognosis method for lithium-ion batteries based on a nonlinear autoregressive exogenous neural network and boxplot[J]. Symmetry, 2021, 13(9): 1714.
- [18] Cai L, Wang H, Dong Z, et al. A multi-fault diagnostic method based on category-reinforced domain adaptation network for series-connected battery packs[J]. Journal of Energy Storage, 2023, 60: 106690.
- [19] 汪善进, 程远. 欧洲新能源汽车现状与发展趋势[J]. 汽车安全与节能学报, 2021, 12(2): 135-149.
- [20] 胡棚湫, 谭泽富, 邱刚, 等. 电动汽车发展综述[J]. 电气应用, 2018, 37(20): 79-85.
- [21] Kumar M S, Revankar S T. Development scheme and key technology of an electric vehicle: An overview[J]. Renewable and Sustainable Energy Reviews, 2017, 70: 1266-1285.
- [22] Suganya R, Joseph L M I L, Kollem S. Understanding lithium-ion battery management systems in electric vehicles: Environmental and health impacts, comparative study, and future trends: A review[J]. Results in Engineering, 2024, 24: 103047.
- [23] Mishra A K, Patial B S. Recent advances in cathode materials for sustainability in lithium-ion batteries[J]. Sustainable Chemistry One World, 2024: 100042.

- [24] 李哲. 纯电动汽车磷酸铁锂电池性能研究[J]. 博士学位论文. 北京: 清华大学, 2011.
- [25] Yang Y, Lun S, Xie J. Multi-fault diagnosis for battery pack based on adaptive correlation sequence and sparse classification model[J]. *Journal of Energy Storage*, 2022, 46: 103889.
- [26] Shang Y, Lu G, Kang Y, et al. A multi-fault diagnosis method based on modified Sample Entropy for lithium-ion battery strings[J]. *Journal of power sources*, 2020, 446: 227275.
- [27] Shang Y, Wang S, Tang N, et al. Research progress in fault detection of battery systems: a review[J]. *Journal of Energy Storage*, 2024, 98: 113079.
- [28] Kang Y, Duan B, Zhou Z, et al. A multi-fault diagnostic method based on an interleaved voltage measurement topology for series connected battery packs[J]. *Journal of Power Sources*, 2019, 417: 132-144.
- [29] 李达, 邓钧君, 张照生, 等. 电动车辆动力电池安全预警策略研究综述[J]. *汽车工程*, 2023, 45(8): 1392-1407.
- [30] 孙振宇, 王震坡, 刘鹏, 等. 新能源汽车动力电池系统故障诊断研究综述[J]. *机械工程学报*, 2021, 57(14): 87-104.
- [31] 洪吉超, 张昕阳, 徐晓明, 等. 基于多熵融合的动力电池故障诊断与应用研究[J]. *机械工程学报*, 2024, 60(12): 301-312.
- [32] Xu Y, Ge X, Shen W, et al. A soft short-circuit diagnosis method for lithium-ion battery packs in electric vehicles[J]. *IEEE Transactions on Power Electronics*, 2022, 37(7): 8572-8581.
- [33] Ding X, Cui Z, Yuan H, et al. Diagnosis of connection fault for parallel-connected lithium-ion batteries based on long short-term memory networks[J]. *Journal of Energy Storage*, 2022, 55: 105552.
- [34] Cheng Y, D'Arpino M, Rizzoni G. Optimal sensor placement for multifault detection and isolation in lithium-ion battery pack[J]. *IEEE Transactions on Transportation Electrification*, 2021, 8(4): 4687-4707.
- [35] Zhao J, Liu M, Zhang B, et al. Review of lithium-ion battery fault features, diagnosis methods, and diagnosis procedures[J]. *IEEE Internet of Things Journal*,

- 2023, 11(11): 18936-18950.
- [36] Niu L, Du J, Li S, et al. An online fault diagnosis method for lithium-ion batteries based on signal decomposition and dimensionless indicators selection[J]. Journal of Energy Storage, 2024, 83: 110590.
- [37] 孙振宇. 基于数据驱动的纯电动汽车动力电池故障诊断方法研究[D]. 北京: 北京理工大学, 2018.
- [38] 王一卉, 姜长泓. 模糊神经网络专家系统在动力锂电池组故障诊断中的应用[J]. 电测与仪表, 2015, 52(14).
- [39] Borujerd S V N, Soleimani A, Esfandyari M J, et al. Fuzzy logic approach for failure analysis of Li-ion battery pack in electric vehicles[J]. Engineering Failure Analysis, 2023, 149: 107233.
- [40] Held M, Brönnimann R. Safe cell, safe battery? Battery fire investigation using FMEA, FTA and practical experiments[J]. Microelectronics Reliability, 2016, 64: 705-710.
- [41] 高迪驹, 兰熙, 沈爱弟. 基于 Petri 网的锂电池故障诊断系统[J]. 系统仿真学报, 2018, 30(2): 614.
- [42] Wu M, Du W, Zhang F, et al. Fault diagnosis method for lithium-ion battery packs in real-world electric vehicles based on K-means and the Fréchet algorithm[J]. ACS omega, 2022, 7(44): 40145-40162.
- [43] Zou B, Zhang L, Xue X, et al. A review on the fault and defect diagnosis of lithium-ion battery for electric vehicles[J]. Energies, 2023, 16(14): 5507.
- [44] Xu Y, Ge X, Guo R, et al. Recent advances in model-based fault diagnosis for lithium-ion batteries: A comprehensive review[J]. Renewable and Sustainable Energy Reviews, 2025, 207: 114922.
- [45] Zhang S, Li J, Li R, et al. Voltage sensor fault detection, isolation and estimation for lithium-ion battery used in electric vehicles via a simple and practical method[J]. Journal of Energy Storage, 2022, 55: 105555.
- [46] Wei J, Dong G, Chen Z. Model-based fault diagnosis of Lithium-ion battery using strong tracking Extended Kalman Filter[J]. Energy Procedia, 2019, 158: 2500-2505.

- [47] Zheng Y, Luo Q, Cui Y, et al. Fault identification and quantitative diagnosis method for series-connected lithium-ion battery packs based on capacity estimation[J]. IEEE Transactions on Industrial Electronics, 2021, 69(3): 3059-3067.
- [48] Gao W, Zheng Y, Ouyang M, et al. Micro-short-circuit diagnosis for series-connected lithium-ion battery packs using mean-difference model[J]. IEEE transactions on industrial electronics, 2018, 66(3): 2132-2142.
- [49] Yu Q, Dai L, Xiong R, et al. Current sensor fault diagnosis method based on an improved equivalent circuit battery model[J]. Applied Energy, 2022, 310: 118588.
- [50] 郭文超, 杨林, 邓忠伟, 等. 云端数据驱动的锂电池故障分级预警研究[J]. 汽车工程, 2023, 45(9): 1677-1687.
- [51] 康永哲. 锂离子电池组容量估计与故障诊断方法研究[D]. 济南: 山东大学, 2021.
- [52] Sun J, Ren S, Shang Y, et al. A novel fault prediction method based on convolutional neural network and long short-term memory with correlation coefficient for lithium-ion battery[J]. Journal of Energy Storage, 2023, 62: 106811.
- [53] Wu X, Wei Z, Wen T, et al. Research on short-circuit fault-diagnosis strategy of lithium-ion battery in an energy-storage system based on voltage cosine similarity[J]. Journal of Energy Storage, 2023, 71: 108012.
- [54] Liu Q, Ma J, Zhao X, et al. Voltage fault diagnosis and misdiagnosis analysis of battery systems using the modified Shannon entropy in real-world electric vehicles[J]. Journal of Energy Storage, 2023, 73: 109287.
- [55] Zhao J, Feng X, Wang J, et al. Battery fault diagnosis and failure prognosis for electric vehicles using spatio-temporal transformer networks[J]. Applied Energy, 2023, 352: 121949.
- [56] Shen D, Lyu C, Yang D, et al. Concurrent multi-fault diagnosis of lithium-ion battery packs using random convolution kernel transformation and Gaussian process classifier[J]. Energy, 2024, 306: 132467.
- [57] Liu H, Li L, Duan B, et al. Multi-fault detection and diagnosis method for battery packs based on statistical analysis[J]. Energy, 2024, 293: 130465.
- [58] Zhao H, Zhang C, Xu L, et al. A deep neural network for multi-fault diagnosis of

- p>
battery packs based on an incremental voltage measurement topology[J].
- Energy*
- , 2025, 316: 134590.
- [59] Zhang C, Zhao S, Yang Z, et al. A multi-fault diagnosis method for lithium-ion battery pack using curvilinear Manhattan distance evaluation and voltage difference analysis[J]. *Journal of Energy Storage*, 2023, 67: 107575.
- [60] Li X, Lyu M, Gao X, et al. An adaptive threshold method for multi-faults diagnosis of lithium-ion batteries based on electro-thermal model[J]. *Measurement*, 2023, 222: 113671.
- [61] 段双明, 常智博. 基于充电电压的串联电池组早期多故障诊断[J]. *储能科学与技术*, 2023, 12(10): 3221.
- [62] Mishra A K, Parmar J, Mukhopadhyay I. Comprehensive review on nucleation, growth, and suppression of lithium dendrites in lithium anode batteries[J]. *Journal of Energy Storage*, 2024, 87: 111421.
- [63] Meng X. Atomic layer deposition of solid-state electrolytes for next-generation lithium-ion batteries and beyond: Opportunities and challenges[J]. *Energy Storage Materials*, 2020, 30: 296-328.
- [64] 王斐. 基于 LSTM 神经网络的锂电池 SOH 预测研究[D]. 重庆: 重庆邮电大学, 2020.
- [65] Zhang Y D, Li Y, Xia X H, et al. High-energy cathode materials for Li-ion batteries: A review of recent developments[J]. *Science China Technological Sciences*, 2015, 58: 1809-1828.
- [66] Nasajpour-Esfahani N, Garmestani H, Bagheritabar M, et al. Comprehensive review of lithium-ion battery materials and development challenges[J]. *Renewable and Sustainable Energy Reviews*, 2024, 203: 114783.
- [67] Luo Y. A review study on the modification and characterization of NCM cathode materials through doping strategies for the improvement of Li-ion batteries[J]. *Advances in Engineering Innovation*, 2024, 14: 39-47.
- [68] Ren D, Feng X, Lu L, et al. Overcharge behaviors and failure mechanism of lithium-ion batteries under different test conditions[J]. *Applied Energy*, 2019, 250: 323-332.

- [69] Ma T, Wu S, Wang F, et al. Degradation mechanism study and safety hazard analysis of overdischarge on commercialized lithium-ion batteries[J]. *ACS Applied Materials & Interfaces*, 2020, 12(50): 56086-56094.
- [70] 刘首彤, 黄沛丰, 白中浩. 锂离子电池机械滥用失效机理及仿真模型研究进展[J]. *汽车工程*, 2022, 44(4): 465-475.
- [71] 杨瑞鑫, 熊瑞, 孙逢春. 锂离子动力电池外部短路测试平台开发与实验分析[J]. *电气工程学报*, 2021, 16(1): 103-118.
- [72] 杨洋. 基于信息物理融合的锂离子电池系统连接松脱故障智能诊断研究[D]. 上海交通大学, 2019.
- [73] 李庭杰. 车用锂离子动力电池组不一致性及连接故障诊断方法研究[D]. 武汉: 华中科技大学, 2020.
- [74] 马名杰. 基于机器视觉的运动目标轨迹获取研究与设计[D]. 四川师范大学, 2024.
- [75] Fang L, Liu S, Cheng F. Early micro-short circuit fault diagnosis of lithium battery pack based on Pearson correlation coefficient and KPCA[J]. *Computers and Electrical Engineering*, 2024, 118: 109481.
- [76] Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. *Physica D: Nonlinear Phenomena*, 2020, 404: 132306.
- [77] 芦俊伟. 基于神经网络的隧道衬砌空洞病害边缘识别方法研究[D]. 石家庄铁道大学, 2022.

攻读硕士期间取得的学术成果

发表的学术论文及专利：

- (1) 发表 2 篇 SCI 期刊论文（中科院二区，中科院三区）。
- (2) 发表一篇学报论文。
- (3) 发表 2 项发明专利。

参与的基金项目：

- (1) 参与两项省级项目。

致谢

时光荏苒，白驹过隙，在研究生的学习生涯即将画上圆满的句点。回首往昔，从初入校园时的青涩懵懂，到如今怀揣理想与抱负即将踏上人生新征程，不禁心潮澎湃，感慨万千。

饮水思源，师恩难忘。首先要向我的导师致以最诚挚的谢意。犹记得研一初定研究方向时的迷茫与焦虑，是老师以其渊博的学识和循循善诱的教导，让我逐渐领略到学术研究的魅力，并为之深深着迷。本课题从选题立意到最终完成，每一个环节都凝聚着老师的心血与智慧。三载春秋，老师不仅在学术研究上给予我悉心指导，更以其严谨的治学态度和谦逊的处世之道，为我树立了为学为人的典范。这份师恩，学生将永远铭记于心。

其次，我想感谢我的实验室同门、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！

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。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，特别感谢各位评审老师的评阅，谢谢！

尚德敏学 唯实惟新

