



基于深度学习的锂电池热失控预警技术研究进展

钟智栋¹, 倪明², 彭继宇², 王嘉晶¹, 赵章风², 蒋建东², 应光耀¹, 马恒¹, 徐静蕾¹
(¹浙江华电器材检测研究院有限公司, 浙江省 杭州市 310000; ²浙江工业大学机械工程学院, 浙江省 杭州市 310023)

摘要: 锂电池型号多样、老化程度差异显著, 且运行工况复杂, 使热失控过程具有较强的不确定性, 导致传统预警手段面临误报率高、时效性低等固有局限。深度学习方法具备挖掘复杂热失控机理和特征演化规律的能力, 可为锂电池热失控早期预警提供有效技术手段。本文围绕“基于深度学习的锂电池热失控预警技术”展开系统性综述, 首先梳理了锂电池热失控关键预警特征、常用数据预处理方法及典型深度学习方法; 其次, 介绍了深度学习方法在锂电池热失控关键参数预测中的应用进展, 并分析了其与物理约束、多物理场耦合模型融合的研究现状; 随后, 总结了基于热失控参数的多级预警策略与多源特征融合技术的实践路径; 最后, 针对锂电池热失控预警面临的故障数据稀缺、模型可解释性不足和模型轻量化部署等挑战开展系统讨论, 并对未来改进方向进行展望。研究表明, 深度学习技术能够有效缓解传统预警手段误报率高、时效性低等问题, 对提升锂电池热失控预警的准确性和及时性具有积极作用。本文可为理解深度学习技术在锂电池热失控预警中的作用机制提供理论参考, 并为推动其在锂电池安全管理系统中的工程应用、完善锂电池安全管理体系提供支撑。

关键词: 锂电池; 热失控; 深度学习; 预警; 联合决策

doi: 10.19799/j.cnki.2095-4239.2026.0145

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-13

Research Progress on Deep Learning-Based Thermal Runaway Early Warning Technology for Lithium-Ion Batteries

ZHONG Zhidong¹, NI Ming², PENG Jiyu², WANG Jiajing¹, ZHAO Zhangfeng², JIANG Jiandong², YING Guangyao¹, MA Heng¹, XU Jinglei¹

(¹Zhejiang Huadian Equipment Testing Research Institute Co., Ltd, Hangzhou 310000, Zhejiang Province, China; ²College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023, Zhejiang Province, China)

Abstract: Lithium-ion batteries feature diverse models, significant variations in aging degrees over their service life, and operation under complex, variable working conditions, including dynamic charge-discharge rates, ambient temperature fluctuations, and mechanical vibrations. These factors collectively endow the thermal runaway process with strong uncertainty. Traditional early warning methods, relying primarily on fixed threshold judgment and simple empirical analysis, struggle to adapt to such diversity and complexity. As a result, they suffer from inherent limitations: high false alarm rates, potential missed alarms, and

收稿日期: 2026-02-09; 修改稿日期: 2026-05-02。

基金项目: 浙江华电器材检测研究院有限公司的科技项目 (5211HD250009), 浙江省“尖兵”领雁”研发攻关计划项目 (2025C02001)。

第一作者: 钟智栋 (1992—), 男, 工程硕士, 工程师, 研究方向为新能源研究与检测工作, E-mail: 597102440@qq.com。通信作者: 彭继宇, 男, 副教授, 研究方向为光学感知技术和智能控制技术研究, E-mail: jypeng@zjut.edu.cn。

引用本文: 钟智栋, 倪明, 彭继宇, 等. 基于深度学习的锂电池热失控预警技术研究进展[J]. 储能科学与技术, XXXX, XX(XX): 1-13.

Citation: ZHONG Zhidong, NI Ming, PENG Jiyu, et al. Research Progress on Deep Learning-Based Thermal Runaway Early Warning Technology for Lithium-Ion Batteries[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-13.

inadequate timeliness, failing to capture the subtle early precursor signals of thermal runaway. In contrast, deep learning methods boast strong nonlinear fitting and autonomous feature mining capabilities, enabling them to deeply explore the complex internal reaction mechanisms of thermal runaway and implicitly capture the dynamic evolution of characteristic parameters throughout its initiation and propagation. This breaks through the bottlenecks of conventional monitoring approaches, offering an effective technical solution for high-precision, advance early warning of lithium-ion battery thermal runaway. This paper conducts a systematic review centered on the theme of "Research Progress on Deep Learning-Based Thermal Runaway Early Warning Technology for Lithium-Ion Batteries". Firstly, it systematically sorts out the core early warning characteristics of thermal runaway, mainstream data preprocessing methods (including cleaning, denoising, normalization, and dataset partitioning), and the structural features and application scenarios of typical deep learning models. Secondly, it elaborates on the application progress of deep learning algorithms in predicting key thermal runaway parameters (e.g., voltage, temperature, gas concentration, state of charge, and state of health), and analyzes the current research status of fusion frameworks integrating deep learning with physical constraints and multi-physics field coupling models, addressing the lack of physical interpretability in pure data-driven models. Subsequently, it summarizes the practical implementation paths of multi-level early warning strategies (aligned with thermal runaway's staged evolution) and multi-source feature fusion technologies that integrate electrical, thermal, gas, and mechanical monitoring data. Finally, the paper systematically discusses core challenges hindering the technology's development and engineering application: the scarcity of real thermal runaway fault data, insufficient interpretability of black-box deep learning models, and difficulties in lightweight deployment on embedded hardware with limited computing power. Corresponding future research priorities and improvement directions are also proposed. Research findings indicate that deep learning effectively mitigates the high false alarm rates and poor timeliness of traditional methods, significantly enhancing the accuracy and timeliness of thermal runaway early warning. This paper provides theoretical references for understanding the mechanism of deep learning in this field, supports its engineering application in lithium-ion battery safety management systems, and contributes to optimizing the full-lifecycle safety assurance system for lithium-ion batteries.

Keywords: Lithium-ion Battery; Thermal Runaway; Deep Learning; Warning; Joint Decision-Making

随着“双碳”目标深入落地、新能源发电大规模并网及电动汽车产业快速扩容，社会对新型储能需求持续增长，锂电池因容量大和寿命长等优势成为了重要的储能装置^[1]。2024年我国锂电池年产量达到 1175 GWh^[2]，2025 年其预估总产量达 1783 GWh^[3]，市场规模巨大。同时锂电池的储能容量也在不断提升。在销量与容量剧增的背景下，热失控问题日益凸显^[4]。锂电池热失控危害巨大，需要深

入发展热失控预警技术以规避风险，保障使用安全。

热失控 (Thermal Runaway, TR) 是指电池内部化学反应的产热速率超过散热速率，使单体电池温度异常上升，进而引发电池组连锁反应，最终起火、爆炸的现象^[5, 6]。热失控内部反应复杂，其宏观表现为锂电池特征参数的异常变化，如温度激增、电压暴跌等^[7]。传统的热失控分析方法难以检

测早期故障，面临误报率高、时效性低等固有局限。此外，锂电池热失控内部机理尚未完全明晰，如微观链式反应、随机缺陷诱导机制，难以通过仿真等方式准确预警热失控，亟需一种高准确率和长提前量的锂电池热失控预警技术^[9]。

深度学习（Deep Learning, DL）由Hinton等人提出，是机器学习的重要分支。其通过模拟人脑神经元构建深层神经网络，自主学习、挖掘数据间的关键特征与内在联系^[9, 10]，可以在未完全掌握热失控机理的背景下对热失控特征参数进行预测。深度学习具有强大的数据驱动与建模能力，可以拟合非线性函数关系，整合多模态数据，自动识别不同特征间的联系^[11]。此外，深度学习技术可通过Transformer等时序模型学习历史数据，捕捉全局时序依赖关系，精准识别热失控的“隐性前兆”，进而提升预警时效性^[12]。

本文的其余部分如下：第1节界定综述范围与边界，第2节阐述热失控关键预警参数及其数据处理方法，第3节综述深度学习在热失控关键参数预测的具体应用，第4节介绍锂电池热失控预警策略与决策，第5节分析深度学习预警锂电池热失控面临的关键挑战以及未来的发展趋势。

1 综述范围与边界

本文以中国知网和Web of Science为检索平台，检索2021年1月1日至2025年12月31日与本综述主题“基于深度学习的锂电池热失控预警技术研究进展”相关的研究文献。在中国知网通过“关键词”搜索“锂电池+热失控”、“热失控+预警”并通过“主题”搜索“深度学习+热失控”。在Web of Science中利用“topic”搜索“lithium ion battery+thermal runaway+warning”、“deep learning+thermal runaway”。如图1所示，该方向文献数量逐年增加，表明基于深度学习的锂电池热失控预警技术已成为研究热点。

2 热失控预警数据特征及建模方法

锂电池数据复杂多样，要有效预警热失控就需要选择与热失控机理密切相关的关键参数^[13]。本节主要介绍锂电池热失控的关键检测参数以及常用的预处理方法和深度学习模型。




图1 近五年有关深度学习预警锂电池热失控的文献数量
Fig. 1 Number of Literatures on Deep Learning-Based Early Warning of Lithium Battery Thermal Runaway in Recent Five Years

2.1 热失控关键检测参数

热失控预警的本质是对锂电池内部化学、物理等特征的异常变化及时作出响应。本综述将与热失控相关的关键检测参数归纳成以下四大类：电特征参数、热特征参数、气体特征参数和状态特征参数。

电特征参数是反应电池充放电情况的重要参数，包括电压、电流等，其异常变化是热失控内短路的重要前兆，可用于提早预判电池热失控^[14]。热特征参数是反映热失控最常用的基础参数，预测温度能清晰地反映热失控当前状况与危害程度，是电池安全管理系统中最重要监测依据之一。气体特征参数是拓展热失控感知维度的重要参数，气体信号通常早于电、热信号出现，是反映热失控更前序、更灵敏的物理指标^[15]。状态特征参数是反映电池长期老化程度的关键参数，主要包含荷电状态（State of Charge, SOC）、健康状态（State of Health, SOH）等，锂电池老化程度会影响热失控触发温度，进而影响热失控的发生概率。

2.2 数据预处理方法

锂电池热失控预警原始数据往往存在数据异常、量级差异、随机噪声等问题，在数据输入给模型前需对数据进行预处理以提升数据质量。常用的数据预处理包括数据清洗、归一化和数据集划分等。

数据清洗主要针对数据中的缺失值、异常值以及噪声。当数据中出现缺失值时，通常会采用均值、中位数或线性插值的方法进行填充；若通过箱线图、聚类等方法检测出异常值，通常会将其剔除。

除, 随后可用针对缺失值的方法进行填补; 对于数据中存在噪声的情况, 则通常采用中值滤波、卡尔曼滤波、小波去噪、去噪自编码器等方式进行去噪^[16]。为消除不同特征参数量纲与数量级差异的影响, 通常需要对原始数据进行归一化处理, 最常用的归一化方式有 Min-Max 归一化和 Z-Score 标准化。Min-Max 归一化即将所有特征参数统一缩放至 [0, 1] 或 [-1, 1]; Z-Score 标准化则是将数据均值归零、方差定为 1。通过归一化与标准化可以使模型学习不同数量级的特征, 避免大数量级数据主导模型权重更新^[17]。为检验模型泛化能力, 避免模型过拟合, 通常会将数据集划分为训练集、验证集和测试集分别用于模型训练、损失计算与性能评估。

2.3 常用深度学习方法

深度学习在锂电池热失控预警中应用广泛, 可代替人工进行热失控关键特征提取, 同时也能胜任时序预测的任务提前响应潜在的热失控^[18]。本节将从热失控特征提取、时序参数建模等方面介绍常用的深度学习模型。

2.3.1 热失控特征提取方法

(1) 卷积神经网络 (Convolutional Neural Networks)

卷积神经网络 (Convolutional Neural Networks, CNN) 是一种前馈神经网络, 是深度学习领域中最具代表性的神经网络之一^[19]。该网络中的卷积结构可用于特征提取, 可从海量锂电池数据中提取出电压、电流和温度等与热失控密切联系的信息。后续可将关键特征输入至长短期记忆网络或其他时序模型, 为预警工作提供关键的信息支撑。卷积神经网络模型既可以保留与热失控机制相关的特征信息^[20], 同时也能压缩数据规模, 降低计算复杂度, 即使在处理锂电池热成像等复杂图像的任务中, 依旧能精准识别热失控状态特征, 及时输出预警信号^[21]。

(2) 自编码器 (Autoencoder)

自编码器 (Autoencoder) 是一种用于半监督或无监督学习的人工神经网络, 其本质是将复杂的数据“压缩”成简洁的“紧凑表示” (Latent Representation)^[22, 23]。利用编码器从多参数高维数据中提取出与热失控相关的核心特征, 再由解码器完成高维数据的重构, 实现对原始数据的“关键特征提取”和“样本重构”。自编码器的训练目标

是减小“重构误差”, 使重构出的高维数据更加逼近原始数据, 从而提升编码器学习数据本质特征的能力, 以及解码器基于本质特征实现数据去噪的能力^[24]。这种训练机制有利于提升预警系统整体把握锂电池热失控关键特征的能力, 减少噪声对预警效果的干扰。

2.3.2 热失控时序参数建模方法

(1) 循环神经网络 (Recurrent Neural Networks)

循环神经网络 (Recurrent Neural Networks, RNN) 是一种专门用于处理时序数据的神经网络^[25]。该网络保留上一时刻输出数据, 用于修正下一时刻的输出结果, 从而捕捉时序数据间的时间依赖性, 在基于历史数据预测锂电池电压、电流、温度等特征的任务中具有良好的表现^[19]。但传统 RNN 也存在处理长序列时出现“梯度消失”与“梯度爆炸”的问题, 因此难以学习长时序数据中的依赖关系^[26]。为了缓解梯度问题, 长短期记忆网络 (Long Short-Term Memory, LSTM) 引入了门控机制, 可对信息进行有效筛选, 实现对信息的选择性记忆、更新与遗忘, 这在一定程度上缓解了传统循环神经网络的梯度消失问题^[27]。

(2) Transformer

Transformer 是一种基于自注意力机制 (Self-Attention) 的深度学习模型, 主要构件包括编码器、解码器和自注意力机制。依托自注意力机制, Transformer 具有强大的特征提取能力, 能够同时捕捉并分析序列中所有元素的内在联系。而在时序预测任务中, Transformer 不同于 RNN 的时间步顺序处理方式, 其通过位置编码将时间顺序注入模型, 从而实现对整个序列的并行建模, 这使其即使在处理锂电池长时序运行数据时依旧能够有效避免梯度问题, 大幅提高了模型对锂电池长期运行工况下数据的预测精度。Transformer 还采用了多头注意力机制, 能将多维输入投影到多个子空间中, 利用多个注意力头并行处理计算繁杂的热失控数据, 优化热失控预警模型的工程执行效率, 弥补其本身因捕捉全序列元素而导致的计算量增加的问题^[28]。

3 锂电池热失控关键参数预测与诊断

热失控关键参数的变化能清晰反映热失控的演化过程, 检测这些关键参数有利于把握分析热失控所处阶段, 提升预警的准确性^[29, 30]。表 1 概述了当

前深度学习在锂电池热失控关键参数预测方面的应用。

表1 深度学习在锂电池热失控诊断方面概述

模型	输入特征	热失控相关输出参数	均方根误差（最优）	辅助技术	文献
去噪卷积自编码器、增量电压分析	电压、电流时序数据	重构电压、电流	电压：10.372 mV； 电流：12.982 mA	K-means 聚类、单类支持向量机等	Jeon et al. (2024) [22]
CNN-LSTM 混合预测模型	电压时序数据	电压	电压：3.4 mV	相关系数矩阵分析、滑动窗口异常放大等	Sun et al. (2023) [31]
Newman-Tiedemann-Gaines-Kim、LSTM-Transformer	放电曲线与充电时序数据	温度	温度（归一化）：0.037	插值补全、归一化、位置编码、滑动窗口等	Cheng et al. (2025) [32]
偏最小二乘回归模型、1D-CNN	热失控气体的拉曼光谱	气体体积分数	气体体积分数：0.405%	小波变换、Savitzky-Golay 滤波、多元散射校正、归一化等	张伟等 (2025) [17]
特征自注意力模块、1D-CNN、Mamba 序列模型	电阻响应信号、气体浓度标签	气体体积分数	气体体积分数：2.3514 ppm	Savitzky-Golay 滤波、列级 Min-Max 归一化、交叉验证	Tang et al. (2025) [33]
PSO-时域卷积网络 TCN-Attention	电压、电流、温度等时序数据，工况	荷电状态	荷电状态：0.41%	箱线图统计等	Li et al. (2024) [16]
奇异值分解健康指标提取模型、Adaptive Sliding Window Pooling Extreme Learning Machine	工况与电池充放电可测参数	电池容量	容量：12.1 mAh	全局平均池化、广义逆矩阵求解输出权重等	Han et al. (2024) [34]
CNN、双向 LSTM	温度、电压	故障分级	/	滑动窗口分析法、归一化	Goswami et al. (2024) [35]

注：粒子群优化（Particle Swarm Optimization, PSO），时域卷积网络（Temporal Convolutional Network, TCN）

3.1 热失控电特征参数预测

热失控会导致电池电压快速骤降，电流出现异常突变。通过预测电池电压、电流等电特征的异常突变可在热失控触发前提前捕捉危险征兆，实现早期精准预警，有效防范热失控引发的起火、爆炸事故。

2023年，Sun 等人^[31]构建了一种融合卷积神经网络和长短期记忆网络的混合模型（CNN-LSTM），图2是该模型预警的框架结构。该模型通过计算相邻锂电池单体之间预测电压的相关系数进行热失控诊断，其在-10℃、0℃、25℃、45℃四个温度下的电压均方根误差均小于0.0055 V，可以精准识别锂电池的轻微故障。然而该研究仅依赖电压数据进行故障预测，易受环境等因素干扰而导致模型预测误差增大，且预警提前量仅1 s，无法为热失控应对预留充足时间，工程实用性有待提升。

锂电池热失控异常数据极度稀缺，实际工程中对于热失控数据采样周期不等，长则可能为数分钟，而时序预测模型则需要大量高完整性与采样频率的数据。针对该问题，Jeon 等人^[22]利用去噪自编码器对实时电压数据进行重构，获得锂电池正常工




图2 CNN-LSTM 模型故障预测框架^[31]
Fig. 2 Fault Prediction Framework of CNN-LSTM Model^[31]

作的电压模板，通过分析电压变化率的重构误差检测热失控故障，图3展现了其预警流程。该方法对数据质量要求低，采用153份采样频率仅为1次/分钟的数据即实现了覆盖全年季节变化、SOC（5%~70%）、电池老化等大多数正常工况下的模型训练，并成功在153份数据中识别出8份异常数据，未出现误报与漏报的情况，验证了自编码器在重构数据任务中的可靠性。

3.2 热失控热特征参数预测

热特征参数是反映热失控状况最直观的特征,包括温度及其变化率。对热特征参数进行预测能清晰地反映出热失控发展状态,判别热失控危害程度。

温度作为锂电池热失控反应的关键特征,是预警锂电池热失控最重要的参数之一。由于实际工程应用中温度传感器布局可能采用U型、螺旋型等随机点位分布,而CNN对此类非规则空间关联的提取能力较差,故Das等人^[36]提出用图神经网络(Graph Neural Network, GNN)进行温度特征提取。该模型温度预测误差小于1℃,且预测步长为350 s,具有较长的热失控应对时间。该研究的局限性是其通过人工设置热点的方式触发热失控,简化了仿真过程,因此难以充分模拟真实场景下热失控的自然传播过程。此外,该研究仿真模型使用新电池参数,而真实热失控案例中的锂电池绝大多数是已使用数年的老电池,这也导致其在实际应用中可能易出现漏报。




图3 DAE 预警流程图^[22]

Fig. 3 Early Warning Flow Chart of DAE^[22]

针对LSTM等模型在长序列预测上性能不足的问题,Cheng等人^[32]借鉴Transformer的自注意力机制,有效弥补了传统LSTM模型对长序列全局趋势捕捉不足的缺陷,并利用多头自注意力机制对温度、电压、等多维度特征进行并行计算,大幅提升了模型对多维度特征的整合能力,并通过预测温度实现了热失控预警。在真实热失控数据的测试中,该模型能在热失控不可逆阶段前的9.55~12.65 s触发预警。此外,该模型完全采用电池管理系统(Battery Management System, BMS)原生数据,可直接嵌入BMS用于自动切断充电,有效避免无人员在场时锂电池充电过程中的热失控风险。

3.3 热失控气体特征参数预测

气体特征参数是拓展热失控感知维度的补充参数,气体扩散速度远快于热传导速率,因此热失控过程中气体异常的出现要早于温度异常,对其进行预测可及时发现热失控前兆,提升预警的时效性。

锂电池热失控会引发SEI膜分解、隔膜熔融、正负极短路等一系列剧烈反应,该过程会产生大量如H₂、CO₂、CO、CH₄等可燃气体^[37, 38],其具体气体成分则与浓度与电池型号、荷电状态等有关^[39, 40]。此时锂电池表面温度尚未有明显变化,通过监测这些特定气体能够更及时发现热失控前兆。张伟等人^[17]基于此思想,提出了一种结合CNN的锂电池热失控特征气体拉曼检测方法。该模型对O₂、H₂、CO₂等六种气体体积分数预测的均方根误差为0.130%~0.405%,能够精准识别锂电池热失控早期气体浓度的微小变化。然而目前拉曼光谱检测的拉曼散射光强度仅为入射光的10⁻⁶,必须搭配高功率激光器、高灵敏度光谱仪才能捕捉。此外,Tang等人^[33]构建了一种名为SACNN-Mamba的融合模型,该模型利用Mamba模块的“选择机制”,动态捕捉与分析气体浓度随时间变化的长期关系,将均方根误差降至2.3514 ppm。该研究以氢气、一氧化碳、乙烯为监测目标,仅依托气体传感器响应初期的20 s片段训练模型,即可实现热失控快速预警。该研究的局限性是训练集、验证集、测试集均在相同工况下采集,三者分布相似,且未考虑传感器老化和杂质气体影响等问题,在实际应用中可能会失效,后续研究可利用联邦学习框架,拓展模型的数据覆盖范围,突破训练数据分布边界的局限性。

3.4 热失控状态特征参数预测

状态特征参数是反映电池长期老化程度的关键参数,主要包含SOC、健康状态(State of Health, SOH)等,两者均与热失控密切相关^[41]。

吕媛媛等人^[42]以18650型三元圆柱形锂电池为实验对象,对0%、50%、100%三种不同SOC下的锂电池开展热失控实验。研究表明,0%、50%、100%SOC下的热失控起始温度分别为183.4℃、152.9℃、128.9℃。SOC越高,锂电池越容易发生热失控。汪红辉等人^[43]对磷酸铁锂电池进行研究,发现SOH与热失控最高温度呈正相关,而与触发温度呈负相关,因此需综合评判不同老化阶段

锂电池的热安全性。SOH理论上可通过容量、内阻直接测量，但实际工程中其测量结果仍旧存在较大误差，因此需要通过深度学习技术提高其预测精度。在捕捉局部数据动态变化上，时域卷积网络（Temporal Convolutional Network，TCN）模型的精度要优于LSTM，在相同条件下TCN能将荷电状态预测误差从1.09%降至0.52%，在识别热失控早期微小异常任务中具有更出色的表现。该模型通过因果卷积与膨胀卷积，捕捉时间序列中的局部动态特征，同时利用残差连接缓解梯度消失问题，使其在处理长时序数据时依然能准确地捕捉特征的瞬时变化趋势^[16]。此外，Han等人^[34]根据相邻窗口数据方差的差值等动态调整窗口大小，可以在数据波动

平稳时增大窗口大小，充分利用历史数据，而在数据波动剧烈时减小窗口大小，增强模型对局部突变的捕捉能力。与传统固定窗口对比，该自适应窗口帮助模型将电池容量的预测RMSE从51.2 mAh减小到了12.1 mAh，降幅高达76.4%。

3.5 融合物理机理的热失控参数预测

纯数据驱动的深度学习方法虽能出色捕捉复杂非线性特征，但可解释性差，在面对极端工况或训练集未覆盖的罕见故障场景时，容易得出违背热力学规律的预测结果。因此需要将深度学习技术与物理机理相融合，引入物理先验知识为模型提供科学的逻辑边界。表2列举了部分融合物理机理的深度学习方法在电池热失控检测方面的应用。

表2 联合物理机理与深度学习模型的电池热失控检测概述

Table 2 Overview of Deep Learning Models Combining Physical Mechanisms and Early Warning Decision-Making

模型	输入特征	热失控相关输出参数	辅助技术	文献
机械-电-热耦合模型、TR温度预测神经网络	材料、工况参数，SOC、温度、电压	温度、力学性能修正系数与内短路电阻等	Z-score 标准化、时间窗口划分等	Li et al. (2025) ^[44]
多物理场耦合模型、GNN-LSTM	材料、工况参数，节点的时序温度	温度	图结构数据构建、Z-score 标准化、时序窗口划分等	Das et al. (2024) ^[36]
PINN	时空坐标与边界/初始条件	完整压力场与流速场方程	拉丁超立方采样、Min-Max 归一化、Runge-Kutta 离散化等	Raissi et al. (2019) ^[45]
模型约束神经网络、双向 LSTM、模型约束自编码器	电压、电流时序数据，锂电池状态参数	组端电压、SOC	逆高斯分布校正、计量回归、概率估计、多级报警阈值设计、迁移学习	Cao et al. (2025) ^[46]
ResNet-CNN 模型、迁移学习模型	仿真与实验电压曲线	故障等级	归一化、源域-目标域数据划分、迁移学习层冻结策略	Zhu et al. (2023) ^[47]

3.5.1 融合物理约束的研究

“物理约束”是保障研究科学性和可靠性的重要原则。物理约束是指基础的物理定律、材料物理属性以及环境约束等，如能量守恒、热传导定律和电极材料热稳定性等约束常被应用于热失控预警中，将物理约束融入深度学习模型之中，能增强模型的可解释性，提升预警的可靠性。

Feng 等人^[48]通过类比 Mallard 火焰前沿理论，证实了热失控前沿的存在，把热失控锋面速度预测的相对误差从无约束的25%降至10%，填补了锂电池内部热失控蔓延规律的认知空白；Cao 等人^[46]将电池等效电路和逆高斯分布规律融入模型，利用逆高斯分布拟合单体电压的真实偏态分布，校正电池包整体段电压与单体偏差，电池包整体SOC预测均方根误差从4.7%降至3.9%。为解决传统深度学习模型缺乏物理约束、数据依赖等问题，Raissi 等人^[45]提出了一种融合物理机理的深度学习模型

(Physics-Informed Deep Learning，PINN)。该模型将已知的物理定律和其他先验知识嵌入到深度学习模型之中，其本质是在损失函数中引入物理残差损失，对模型偏离物理约束时施加惩罚，使其在始终满足物理约束的条件下拟合数据。该方法能让模型在严格遵循基本规律的基础上学习数据，从而提高模型的可靠性和可解释性。此外，物理定律本身即是无限的数据源，能不断训练模型如何得出真正的有效解，缓解了模型对真实标记数据的依赖。该研究模型仅采用5000个流速数据点，占可用数据点的1%，即可还原完整的压力场与流速场，将流项参数和粘性项参数误差分别降至0.078%、4.67%。将物理约束融入深度学习预警模型，不仅能提升模型的可解释性，也能缓解数据点稀缺的问题，增强预测结果的可信度。

3.5.2 融合多物理场耦合模型的研究

多物理场耦合模型是指两种及以上物理场相互

作用的数学-数值模型。实际工程中的锂电池热失控物理过程就是多物理场耦合作用的结果。通过多物理场耦合模型能揭示各物理场间的内在关系,为热失控故障诊断提供依据。锂电池热失控预测中常用的耦合模型主要包括电热耦合模型、热化学耦合模型等^[49, 50]。

为提高锂电池的安全性和循环寿命,明确不同放电倍率、冷却条件下锂电池温度变化规律,Domalanta等人^[51]通过建立电化学-热耦合模型,实现了对不同放电倍率下电压与温度变化的精准预测,将电压与温度预测的均方根误差降至0.06 V与1.5153 K。多物理场耦合模型能揭示锂电池热失控的演化规律,但由于不同型号电池正负极、电解质与热失控链式反应不同,致使单一耦合模型难以适配多种型号的锂电池。多物理场耦合模型虽然计算复杂度过高,难以满足实时性要求,但其可借助云计算,弥补计算量过大的缺陷,并将物理定律作为约束,让预警从纯数据拟合升级为机理驱动。Li等人^[44]提出了融合深度学习模型的机械-电-热耦合混合模型,反推负极力学性能修正系数与内短路电阻等参数,并生成30%与真实故障数据高度相似的仿真数据用于模型训练,优化了模型在不同SOC、加载速度、压头类型等工况下的预测能力。在12种不同工况下,其预测温度的平均绝对误差均小于1℃。将多物理场耦合模型与深度学习融合,不仅能帮助研究者更深入地解析锂电池热失控的内在机理,也能为模型预测提供坚实的数据支撑。目前物理场耦合模型最大的局限性在于物理场构建不全面,难以全面分析锂电池热失控的各种诱因,导致模型的泛化能力较弱。另外,由于研究者为简化仿真计算,通常对模型进行均质化、无缺陷等理想假设,使得仿真结果会与实际存在偏差。后续研究应尽可能构建更加全面的物理场耦合模型,细化模型构建,进一步提升仿真结果质量。

4 锂电池热失控预警策略与决策

预警策略指在风险发生之前,通过数据分析和情景预测等方法,及时识别潜在问题并采取预防措施。热失控预警不能仅仅通过深度学习技术预测锂电池热失控的关键参数,更要搭建一套基于预测结果进行响应的预警机制,本节将重点介绍多级预警机制以及多源信息融合的预警策略。

4.1 多级预警机制与风险分级应用

由于热失控是一个渐进式、多阶段的演化过程,通过多级预警可分级响应不同阶段的风险,常用的多级预警方式有三级预警、四级预警以及五级预警策略,如Zhu等人^[47]以内短路电阻为核心指标,将热失控内短路故障划分为4级故障。其利用ResNet-CNN模型学习电压曲线并建立与ISC故障等级的映射关系,以实时采集的锂电池归一化电压为模型输入,就能直接输出故障分类的结果,触发对应分级预警。该融合模型在实验数据集上判断准确率高达96.67%,仅在极轻微短路时出现少量误判。Goswami等人^[35]则是基于最高表面温度将热失控划分为安全阶段、过渡阶段、热失控阶段,对比了VGG、ResNet、EfficientNet等多种CNN架构的分类性能,其中EfficientNetB7效果最优,召回率达到98%,可精准区分安全、临界和热失控状态。多级预警策略能更好地适应热失控的渐进式过程,精准反映电池当前所处的热失控阶段,并针对不同阶段及时采取针对性防控措施,利于区分正常工况波动与真实故障前兆,避免电流突变、温度波动等干扰导致误报^[52, 53]。

4.2 多源信息融合在预警系统中的应用

由于锂电池热失控是电压骤降、温度飙升等多物理场耦合作用的复杂过程,仅依赖单一特征参数进行预测易出现误报和预警失败等问题,采用多源特征融合预警技术可以减少此类问题的出现,提升预警的精度^[54]。该技术主要有三种路径,分别为早期数据级融合、中期特征级融合以及后期决策级融合。

数据融合是指将电压、温度等多种原始数据拼接成多维向量,该方法能挖掘各个特征之间的潜在联系,其合并需进行归一化处理,以免大数量级特征主导权重偏移,降低预测精度。如Li等人^[16]将锂电池的电压、电流、温度三类原始数据通过归一化整合后输入给PSO-TCN-Attention模型。该模型的SOC预测均方根误差低于1%,推理时间为0.0622 ms,可满足BMS的精度和实时性要求。特征级融合指用多种特征提取网络提取不同来源的数据并进行预处理。如Tang等人^[33]利用特征自注意力模块提取不同传感器间的空间关联,同时采用一维卷积神经网络模块和Mamba模块分别提取数据短期和长时序依赖关系,最终通过全连接层输出气

体浓度预测结果，其测试集 RMSE 仅为 2.3514 ppm。该方法能进一步强化数据间的联系，对提高预警精度具有重要作用。决策级融合是指对不同来源数据建立各自独立的预警子模型，最终决策模型则对各子模型的决策进行综合评价。韩腾飞等人^[59]采用分布式训练客户端监测航天器锂电池，将联邦学习框架与对比学习相融合，其融合模型在保护各设备终端隐私的前提下，精度与鲁棒性也远优于单设备独立训练模型。该研究很好地表明跨设备数据协同训练无需依赖原始数据的集中管理，通过分布式训练与模型参数的跨设备共享，即可实现多设备数据的有效知识融合。该分布式训练架构模型预测健康状态的均方根误差仅为 0.0147%，优于传统的集中式训练模型。多源特征融合预警技术有利于解决单一参数预警带来的滞后性、误报率高、场景适应性差等问题，是目前深度学习在热失控预警领域中的核心发展方向之一。

5 锂电池热失控预警的关键挑战与发展趋势

深度学习在捕捉电池热失控的时序演化特征与多维信息集成方面具有显著优势，但在实际工程化落地过程中仍面临着重大挑战。如深度学习预警性能依赖训练数据，而真实热失控实验样本极度匮乏；深度学习模型目前阶段可解释性较弱，其结果容易违背现实物理规律；为提升模型预测精度，通常需要深化模型结构，这与轻量化部署的工程化需求具有冲突。

5.1 真实热失控故障数据稀缺问题

深度学习模型作为数据驱动模型，其性能高度依赖大规模、高质量的数据，而在实际工程场景中，获取全工况全生命周期的锂电池热失控故障数据极其困难。虽然研究者通过实验室加速老化实验或人工设置热点的方式获取数据，但实验室环境下的诱发机制与实际工况仍存在显著差异。实验室多采用外部加热、过充等强干扰手段，而真实热失控常源于内部缺陷、SEI 膜非均匀分解或局部微短路等隐蔽因素，这种数据生成逻辑的差异导致模型在面对自发性热失控时识别率大幅下降^[36]。此外，仿真数据虽在一定程度上缓解了热失控故障数据稀缺的问题，然而现有耦合模型为降低计算复杂度，常对电池内部结构做均质化、无缺陷等理想化假设，

这使得仿真生成的数据集存在失真的风险。同时目前多数研究仍基于新电池数据建模，并未考虑锂电池老化的影响，使模型在长周期应用中容易出现漏报风险。另外，不同化学体系的锂电池在产热速率、起始温度等特性上差异显著，这使得单一模型往往只能应用于某一型号的锂电池预警中。如 Domalanta 等人^[61]虽然在特定软包电池上取得了高精度，但其物理参数完全依据单一软包电池构建，不适用于磷酸铁锂或高镍三元体系。

针对热失控故障数据缺失，模型普适性不足的问题，生成对抗网络（Generative Adversarial Networks, GAN）、深度信念网络（Deep Belief Networks）等生成式模型及多物理场耦合仿真模型可在一定程度上缓解该问题^[36, 56, 57]，但生成的仿真样本与真实样本仍存在一定差异。未来需进一步提升生成式模型的样本生成能力，避免简化模型而导致数据真实性不足的问题；此外可通过引入数字孪生技术，构建多维数字映射模型，构建仿真数据的实时交互功能，以适应预警的实时性要求；探索联邦学习的分布式训练框架，在保护各设备终端隐私的前提下，通过分布式训练与模型参数的跨设备共享，实现多设备数据的有效知识融合，提升模型跨场景、跨电池类型的泛化性能^[59]。

5.2 热失控预警模型的可解释性问题

尽管深度学习架构在残差最小化和特征拟合方面表现卓越，但其黑箱特性与工业安全领域对逻辑透明度的刚性需求之间存在显著矛盾。目前，大多数基于 CNN、LSTM 或 Transformer 的预警模型仅能输出概率值或残差波动的判定结果，无法提供符合电化学机理的失效逻辑支撑^[22]。纯数据驱动模型在训练过程中常忽略质量、能量守恒及热力学演化等规律。在缺乏物理约束的情况下，模型输出的预测曲线在数值上接近真实值，但在物理逻辑上可能已违背常理。虽然 Raissi 等学者^[49]提出了物理机理融合的 PINN 框架，Cao 等人^[46]在模型中引入了逆高斯分布校正，试图通过损失函数惩罚偏离物理定律的行为，但这些尝试仍处于起步阶段。在多物理场高度耦合的热失控演化过程中，如何将复杂的非线性化学反应动力学方程与高维神经网络层深层嵌套，而非简单的后处理校正，依然是当前研究的难点。只有实现物理先验知识与数据特征的深度融合，才能从根源上缓解模型在极端工况下的失效问

题,提升预警系统的科学性与可解释性。

针对当前物理机理描述不完备以及多物理场耦合维度缺失的瓶颈^[5],未来应深化物理机理对深度学习模型的指导作用。将构建全维度、高保真度的多物理场耦合框架作为重点研究方向之一,通过引入电-化学-热-力等更加全面的物理场深度耦合机制,精准还原电池热失控全过程的复杂演化规律,为深度学习模型提供更严谨、更具普适性的物理逻辑支撑;同时要完备物理约束对深度学习模型的指导作用,降低数据偏差与过拟合风险,提升故障预警与决策输出的可解释性,厘清特征变化与热失控演化的内在因果关联,最终构建一套机理清晰、因果明确的电池安全预警感知体系。

5.3 热失控模型轻量化部署问题

模型预警精度优化与实时部署的工程化需求之间存在显著的权衡冲突。为了捕捉自产热起始阶段的微弱信号,研究者倾向于引入参数规模巨大的模型架构,如具备多头注意力机制的 Transformer 或基于选择机制的 Mamba 模型^[33, 34]。这些架构在特征整合与长序列建模方面具备更大的优势,但其算力需求与显存占用远超 BMS 微控制器或边缘芯片的承载能力。目前的实验多依赖高功率 GPU 服务器进行离线分析,而实际 BMS 要求毫秒级的响应速度,这使得许多高复杂性算法在落地过程中面临阻碍。传感器的精密化需求与环境的恶劣性也存在脱节现象。如张伟等人^[17]提出的拉曼光谱检测技术能极早地通过气体成分识别风险,但该设备所需的高灵敏度光学元件和稳定激光源极易受振动、粉尘及环境温度等影响。此外,实验室研究常采用商用传感器,其采样频率与 BMS 具有差异。如 Das 等人^[36]的采样频率仅为 1 Hz,远低于 BMS 热失控传感器的典型采样频率。利用高频传感器进行采集会大幅增加数据量,导致模型计算量增加,推理延迟增大,难以满足 BMS 系统的实时性要求。

为进一步推动该技术的工程化落地,开发出真正能够集成于 BMS 的嵌入式实时预警体系,必须克服底层硬件适配与高性能算法之间的矛盾。需在保证预警精度的前提下,深度开展针对深度神经网络的轻量化技术研究,以适配 BMS 算力和内存资源有限的实际情况^[48];针对热失控快速发展的特性,通过将边缘计算与云计算技术深度融合,兼顾预警实时性与准确度。在 BMS 终端(边缘侧)利

用轻量化模型完成实时数据的初步判断,确保预警的低延迟响应,同时借助云端服务器强大的算力支撑,运行参数维度更高、计算逻辑更复杂的深层高精度模型,对电池状态进行长周期的精准趋势分析。

6 结论

本文系统梳理了深度学习技术在锂电池热失控预警中的研究进展,涵盖热失控特征类型及数据预处理和建模方法分析、热失控关键特征预测应用,以及热失控预警策略讨论。针对当前研究现状及存在的主要问题,本文的分析与讨论可归纳为以下几点:

(1) 热失控预警已由传统阈值判断逐步转向深度学习驱动的多特征预测。电压、电流、温度等 BMS 原生数据易获取、易部署,温度变化率, SOC、SOH 等状态特征及气体特征有助于拓展早期感知维度。但深度学习模型高度依赖训练数据,真实故障数据获取困难,实验和仿真数据难以覆盖复杂工况。未来应提升生成式模型和多物理场耦合仿真的数据扩展能力,并结合数字孪生、迁移学习和联邦学习,提高模型泛化能力。

(2) 深度学习模型已在关键参数预测中取得较好效果,但可解释性不足仍限制其安全应用。CNN、LSTM、Transformer 等模型能够提高电压、温度、SOC、SOH 和气体浓度等参数的预测精度,但纯数据驱动模型缺乏电化学反应、热传导、能量守恒等机理支撑,在极端工况下可靠性不足。未来应加强物理约束与深度学习模型融合,将电-化学-热-力等多物理场耦合规律融入模型构建,提升预测可信度和可解释性。

(3) 热失控预警正由单一参数预测转向分级响应和多源融合决策,但工程化应用仍受实时性和轻量化限制。多级预警和多源融合可降低误报、漏报风险,但 Transformer 等高精度模型参数量大、计算复杂,与 BMS 算力、存储、功耗和实时响应要求存在矛盾。未来应面向 BMS 实际部署需求,发展边缘端轻量化模型,并结合边缘计算与云计算,实现低延迟预警与长周期状态分析协同。

参考文献

- [1] MACHLEV R. EV battery fault diagnostics and prognostics using

- deep learning: Review, challenges & opportunities [J]. *Journal of Energy Storage*, 2024, 83. 110614.
- [2] 王海波, 张春强, 林虹, 等. 2024年中国电池行业运行情况 [J]. *电池*, 2025, 55(01): 11-18.
WANG H B, ZHANG C Q, LIN H, et al. Operation status of China's battery industry in 2024 [J]. *Battery Bimonthly*, 2025, 55 (01): 11-18.
- [3] 王海波, 钱飞宏, 林虹, 等. 2025年中国电池行业运行情况 [J]. *电池*, 2026, 56 (01): 6-15.
WANG H B, QIAN F H, LIN H, et al. Operation status of China's battery industry in 2025[J]. *Battery Bimonthly*, 2026, 56(1): 6-15..
- [4] 陈素华, 白莹. 锂离子动力电池热失控机理及热管理技术研究进展 [J]. *中国科学基金*, 2023, 37(02): 187-198.
CHEN S H, BAI Y. Research progress on thermal runaway mechanism and thermal management technology of lithium-ion power batteries [J]. *Science Foundation in China*, 2023, 37 (02): 187-198.
- [5] 李远茂. 动力锂离子电池性能关键估计参数建模与计算方法研究. 华南理工大学, 2024.
LI Y M. Research on modeling and calculation methods of key estimation parameters for power lithium-ion battery performance [D]. *South China University of Technology*, 2024.
- [6] WANG Z, SADEGHI H, HUANG X, et al. Thermal runaway and flame propagation in battery packs: numerical simulation and deep learning prediction [J]. *Engineering Applications of Computational Fluid Mechanics*, 2025, 19(1). 2445160.
- [7] 张小龙, 孙承章, 王旭, 等. 基于虚拟防火墙的电化学储能系统热蔓延抑制策略 [J]. *太阳能学报*, 2025, 46(02): 41-51.
ZHANG X L, SUN C Z, WANG X, et al. Thermal runaway propagation suppression strategy of electrochemical energy storage system based on virtual firewall [J]. *Acta Energiæ Solaris Sinica*, 2025, 46 (02): 41-51.
- [8] 朱学慢. 锂电池的热失控研究. 上海海洋大学, 2021.
ZHU X M. Research on thermal runaway of lithium battery [D]. *Shanghai Ocean University*, 2021.
- [9] HINTON GE, SALAKHUTDINOV RR. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507. 1127647.
- [10] MCCULLOCH WS, PITTS W. A logical calculus of the ideas immanent in nervous activity. 1943 [J]. *Bulletin of mathematical biology*, 1990, 52(1-2): 99-115.
- [11] 王天城. 电动汽车动力电池热失控状态评估方法及应用研究. 哈尔滨工业大学, 2021.
WANG T C. Research on state evaluation method and application of thermal runaway of power battery for electric vehicles [D]. *Harbin Institute of Technology*, 2021.
- [12] 栗家傲. 基于深度学习的动力电池异常检测算法研究. 北京邮电大学, 2023.
LI J A. Research on abnormal detection algorithm of power battery based on deep learning [D]. *Beijing University of Posts and Telecommunications*, 2023.
- [13] Yao L, Fang Z, Xiao Y, Hou J, Fu Z. An intelligent fault diagnosis method for lithium battery systems based on grid search support vector machine. *Energy* 2021;214:118866.
- [14] KONG X, LU L, YUAN Y, et al. Foreign matter defect battery and sudden spontaneous combustion [J]. *eTransportation*, 2022, 12.
- [15] YANG H S, Li X Y, Fu K, et al. Behavioral description of lithium-ion batteries by multiphysics modeling[J]. *DeCarbon*, 2024, 6: 100076.
- [16] LI F, ZUO W, ZHOU K, et al. State of charge estimation of lithium-ion batteries based on PSO-TCN-Attention neural network [J]. *Journal of Energy Storage*, 2024, 84. 110806.
- [17] 张伟, 杨旭, 黄鑫, 等. 基于PLSR-CNN的锂电池热失控特征气体拉曼检测方法 [J]. *消防科学与技术*, 2025, 44(04): 525-531.
ZHANG W, YANG X, HUANG X, et al. Raman detection method for thermal runaway characteristic gases of lithium battery based on PLSR-CNN [J]. *Fire Science and Technology*, 2025, 44 (04): 525-531.
- [18] Ma M, Wang Y, Duan Q, Wu T, Sun J, Wang Q. Fault detection of the connection of lithium-ion power batteries in series for electric vehicles based on statistical analysis. *Energy* 2018;164:745 – 56.
- [19] LI Z, LIU F, YANG W, et al. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(12): 6999-7019. 3084827.
- [20] BERTONI F, MONTOBIBIO N, Sarti A, et al. Emergence of Lie Symmetries in Functional Architectures Learned by CNNs [J]. *Frontiers in Computational Neuroscience*, 2021, 15. 694505.
- [21] NAJJAR R. Redefining Radiology: A Review of Artificial Intelligence Integration in Medical Imaging [J]. *Diagnostics*, 2023, 13(17). 2760.
- [22] JEON J, CHEON H, JUNG B, et al. ProADD: Proactive battery anomaly dual detection leveraging denoising convolutional autoencoder and incremental voltage analysis [J]. *Applied Energy*, 2024, 373. 123757.
- [23] CUI B, WANG H, LI R, et al. Long-sequence voltage series forecasting for internal short circuit early detection of lithium-ion batteries [J]. *Patterns (New York, NY)*, 2023, 4(6): 100732-100732.
- [24] TIAN L, DONG C, WANG R, et al. Anti-interference lithium-ion battery intelligent perception for thermal fault detection and localization [J]. *IET Energy Systems Integration*, 2024, 6(4): 593-605.
- [25] PEARLMUTTER BA. Gradient calculations for dynamic recurrent neural networks: a survey [J]. *IEEE transactions on neural networks*, 1995, 6(5): 1212-1228.
- [26] PASCANU R, MIKOLOV T, BENGIO Y. On the difficulty of training Recurrent Neural Networks [J]. *arXiv*, 2013. 5063.
- [27] VAN Houdt G, MOSQUERA C, Napoles G. A review on the long short-term memory model [J]. *Artificial Intelligence Review*, 2020, 53(8): 5929-5955.
- [28] VASWANI A, SHAZEER N, PARMAR N, et al. Attention Is All You Need. In: Guyon I, Luxburg U, Bengio S, Wallach H, Fergus R, Vishwanathan S, Garnett R, editors. 31st Annual Conference on

- Neural Information Processing Systems (NIPS); 2017 2017 Dec 04 - 09; Long Beach, CA; 2017.
- [29] Cai L, Li J, Xu X, Jin H, Meng J, Wang B, et al. Automatically constructing a health indicator for lithium-ion battery state-of-health estimation via adversarial and compound staked autoencoder. *J Energy Storage* 2024;84:110711.
- [30] 蒋建杰, 楼平, 徐国华, 等. 基于预测误差的锂离子电池热失控预警方法研究 [J]. 储能科学与技术, 2024, 13(11): 4187-4197.
- JIANG J J, LOU P, XU G H, et al. Research on thermal runaway early warning method of lithium-ion battery based on prediction error [J]. *Energy Storage Science and Technology*, 2024, 13 (11): 4187-4197.
- [31] 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.
- [32] CHENG Y M, GAO D X, ZHAO F M, et al. A data-driven early warning method for thermal runaway during charging of lithium-ion battery packs in electric vehicles [J]. *Measurement Science and Technology*, 2025, 36(1). 016233.
- [33] TANG M, ZHANG X, ZHANG C, et al. An intelligent sensing array for thermal runaway characteristic gas concentration prediction based on SACNN-Mamba [J]. *Sensors and Actuators B-Chemical*, 2025, 431. 137368.
- [34] HAN C, YUAN H. Capacity prediction of Lithium-ion batteries based on adaptive sliding window pooling extreme learning machine algorithm [J]. *Physica Scripta*, 2024, 99(1). 016003.
- [35] GOSWAMI B R D, MASTROGIORGIO M, RAGONE M, et al. A combined multiphysics modeling and deep learning framework to predict thermal runaway in cylindrical Li-ion batteries [J]. *Journal of Power Sources*, 2024, 595. 234065.
- [36] DAS GOSWAMI B R, ABDISOBOUHI Y, DU H, et al. Advancing battery safety: Integrating multiphysics and machine learning for thermal runaway prediction in lithium-ion battery module [J]. *Journal of Power Sources*, 2024, 614. 235015.
- [37] LIN L, EZEKOYE O. Time-resolved characterization of toxic and flammable gases during venting of Li-ion cylindrical cells with current interrupt devices [J]. *Journal of Loss Prevention in the Process Industries*, 2025, 94. 105488.
- [38] 黄峥, 秦鹏, 石晗, 等. 过热条件下 86 Ah 磷酸铁锂电池热失控行为研究 [J]. 高电压技术, 2022, 48(03): 1185-1191.
- HUANG Z, QIN P, SHI H, et al. Research on thermal runaway behavior of 86 Ah lithium iron phosphate battery under overheating condition [J]. *High Voltage Engineering*, 2022, 48 (03): 1185-1191.
- [39] ZHANG Q, LIU T, HAO C, et al. In situ Raman investigation on gas components and explosion risk of thermal runaway emission from lithium-ion battery [J]. *Journal of Energy Storage*, 2022, 56. 105905.
- [40] WANG H, XU H, ZHANG Z, et al. Fire and explosion characteristics of vent gas from lithium-ion batteries after thermal runaway: A comparative study [J]. *Etransportation*, 2022, 13. 100190.
- [41] 暴祥. 基于多任务学习和对抗域适应的车载锂电池状态估计研究. 内蒙古科技大学, 2024.
- BAO X. Research on state estimation of vehicle-mounted lithium battery based on multi-task learning and adversarial domain adaptation [D]. Inner Mongolia University of Science and Technology, 2024.
- [42] 吕媛媛, 洪颖, 丁斌, 等. 新能源锂离子电池热失控性能研究 [J]. 储能科学与技术, 2026, 15 (02): 391-397.
- LYU Y Y, HONG Y, DING B, et al. Study on thermal runaway performance of new energy lithium-ion batteries [J]. *Energy Storage Science and Technology*, 2026, 15(02): 391-397.
- [43] 汪红辉, 李嘉鑫, 储德韧, 等. 磷酸铁锂电池存储失效机理及热安全性研究 [J]. 储能科学与技术, 2025, 14 (05): 1797-1805.
- WANG H H, LI J X, CHU D R, et al. Study on storage failure mechanism and thermal safety of lithium iron phosphate batteries [J]. *Energy Storage Science and Technology*, 2025, 14(05): 1797-1805.
- [44] LI J, ZHANG Y, YUAN B, et al. A Data-Driven Thermal Runaway Warning Method for Lithium-Ion Batteries Under Mechanical Abuse [J]. *Ieee Transactions on Transportation Electrification*, 2025, 11(2): 5169-5179.
- [45] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [46] CAO R, ZHANG Z, SHI R, et al. Model-constrained deep learning for online fault diagnosis in Li-ion batteries over stochastic conditions [J]. *Nature Communications*, 2025, 16(1). 1651.
- [47] ZHU G, SUN T, XU Y, et al. Identification of Internal Short-Circuit Faults in Lithium-Ion Batteries Based on a Multi-Machine Learning Fusion [J]. *Batteries-Basel*, 2023, 9(3). 154.
- [48] FENG X, ZHANG F, FENG J, et al. Propagation dynamics of the thermal runaway front in large-scale lithium-ion batteries: Theoretical and experiment validation [J]. *International Journal of Heat and Mass Transfer*, 2024, 225. 125393.
- [49] KIM S W, KWAK E, KIM J H, et al. Modeling and prediction of lithium-ion battery thermal runaway via multiphysics-informed neural network [J]. *Journal of Energy Storage*, 2023, 60. 106654.
- [50] 张浩轩, 王寅达, 王一尧, 等. 高功率微波作用下三维结构中多物理场耦合过程仿真方法研究综述 [J]. 电波科学学报, 2024, 39(05): 852-869.
- ZHANG H X, WANG Y D, WANG Y Y, et al. Review on simulation methods of multi-physics field coupling process in three-dimensional structures under high-power microwave action [J]. *The Chinese Journal of Radio Science*, 2024, 39 (05): 852-869.
- [51] DOMALANTA M R B, PARAGGUA J A D R. A Multiphysics Model Simulating the Electrochemical, Thermal, and Thermal Runaway Behaviors of Lithium Polymer Battery [J]. *Energies*, 2023, 16(6). 2642.
- [52] GAO D, DU Y, CHENG Y, et al. Research on dynamic multi-level

- warning method for thermal runaway charging of electric vehicles [J]. *Engineering Applications of Artificial Intelligence*, 2024, 132: 107919.
- [53] 王弘. 大容量锂离子电池热失控多参数分级预警技术研究[D]. 武汉理工大学, 2024.
- WANG H. Research on Multi-parameter Graded Early Warning Technology for Thermal Runaway of Large-capacity Lithium-ion Batteries[D]. Wuhan University of Technology, 2024.
- [54] 刘阳阳, 叶晓宇. 基于多参数融合圆柱形三元锂电池热失控预警研究 [J]. *汽车与驾驶维修(维修版)*, 2024(08): 41-43.
- LIU Y Y, YE X Y. Research on thermal runaway early warning of cylindrical ternary lithium batteries based on multi-parameter fusion [J]. *Auto Driving & Service*, 2024(08): 41-43.
- [55] 韩腾飞, 李然, 谢宇嘉,等. 基于联邦对比学习航天器锂电池健康状态评估 [J]. *航天控制*, 2025, 43 (03): 76-83.
- HAN T F, LI R, XIE Y J, et al. State of health assessment of spacecraft lithium-ion batteries based on federated contrastive learning[J]. *Aerospace Control*, 2025, 43(3): 76-83.
- [56] GOODFELLOW IJ, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Nets. In: Ghahramani Z, Welling M, Cortes C, Lawrence N, Weinberger K, editors. 28th Conference on Neural Information Processing Systems (NIPS); 2014 2014 Dec 08 - 13; Montreal, CANADA; 2014. p. 2672-2680.
- [57] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7): 1527-1554.