

DOI:10.20033/j.1003-7241.(2026)06-0013-06

基于 IC 曲线的锂离子电池内短路早期诊断

陈 宪¹, 赖桑愉¹, 麦允强¹, 关 湘¹, 张文灿²

(1. 广东盈通智联数字技术有限公司, 广东 佛山 528000; 2. 佛山大学, 广东 佛山 528225)

摘要:为提升锂离子电池内短路故障的早期检测能力,提出一种基于卷积神经网络(convolutional neural network, CNN)与长短期记忆网络(long short-term memory, LSTM)融合的内短路诊断方法。首先将电池充电过程中的电压曲线转换为容量增量(incremental capacity, IC)曲线,并利用快速傅里叶变换(fast fourier transform, FFT)对 IC 曲线进行平滑处理,从中提取电池内部状态变化特征,进而采用 CNN 提取 IC 曲线中的局部特征,再通过 LSTM 捕获长期依赖信息,最终实现内短路故障的分类检测。通过并联电阻模拟不同程度的早期内短路故障,构建包含 5 000 组样本的数据集。结果表明,以 IC 曲线为特征时, CNN-LSTM 融合模型对故障等级的分类准确率达 88.62%,显著优于单一模型,并能有效区分故障严重程度。该方法为电池管理系统智能故障诊断提供了有效方案。

关键词:锂离子电池;内短路检测;卷积神经网络;长短期记忆网络;容量增量曲线

中图分类号: TP183 **文献标志码:** A **文章编号:** 1003-7241(2026)06-0013-06

Early diagnosis of internal short circuit in lithium-ion batteries based on incremental capacity curves

Chen Xian¹, Lai Sangyu¹, Mai Yunqiang¹, Guan Xiang¹, Zhang Wencan²

(1. Guangdong Yingtong Zhilian Digital Technology Co., Ltd., Foshan 528000, Guangdong, China;

2. Foshan University, Foshan 528225, Guangdong, China)

Abstract: To address the challenges of detecting the concealed early-stage characteristics of internal short circuits (ISC) in lithium-ion batteries, and the inability of existing methods to simultaneously capture local features and model temporal evolution, this study proposes a diagnostic method based on a hybrid convolutional neural network (CNN) and long short-term memory (LSTM) architecture. This approach aims to enhance the battery management system's (BMS) capability to perceive and classify micro-short circuit faults of varying severities. First, leveraging the high sensitivity of incremental capacity (IC) curves to internal electrochemical phase transitions, charging voltage data is converted into IC curves to amplify subtle fault signals. A fast fourier transform (FFT) is then introduced to filter high-frequency noise generated during the differentiation process, effectively preserving key peak and valley features of the curves. Subsequently, a series CNN-LSTM network is designed, a one-dimensional CNN extracts local spatial morphological features from the IC curves, while the LSTM captures the long-term dependency rules of fault evolution over time, establishing an end-to-end fault diagnosis model. In the experiments, four fault states ranging from early-stage micro-short circuits to severe short circuits were simulated by connecting resistors of different resistance values in parallel to 18650 batteries, constructing a balanced dataset containing 5 000 samples. The results demonstrate that the proposed method achieves a test accuracy of 88.62% in the five-category classification task, with the recognition rate for severe short circuits reaching 93.5%. Comparative analysis confirms that the performance of this hybrid model is significantly superior to that of standalone CNN or LSTM networks. It effectively distinguishes the severity of internal short circuits, providing a high-precision technical solution for intelligent battery safety early warning systems.

Keywords: lithium-ion battery; internal short-circuit detection; convolutional neural network; long short-term memory network; incremental capacity curve

锂离子电池以其高能量密度、长寿命和低自放电率等优点,已成为电动汽车、储能系统等领域和便携式电子设备的首选能量来源^[1-3]。然而,随着锂离子电池的广泛应用,其安全问题也日益突出。内短路故障是导致锂离子电池出现安全风险的主要原因之一^[4-7],当发展到一定的程度会触发发热失控,带来严重的安全隐患。因此,锂离子

电池内短路故障的早期检测和诊断对于确保电池系统的安全运行具有重要意义。

现有的锂离子电池内短路故障诊断方法主要分为模型驱动和数据驱动两类^[8-9]。文献[10]利用弛豫电压分析法,通过比较电池荷电状态(state of charge, SoC)的估算值与安时积分法计算值进行内短路检测,但此法依赖于

收稿日期:2025-04-24;录用日期:2025-07-17

基金项目:广东省基础与应用基础研究项目(2023A1515140004)

作者简介:陈 宪(1981—),男,工程师,研究方向:系统状态估计与安全,电力行业故障诊断技术。

引用本文:陈宪, 赖桑愉, 麦允强, 等. 基于 IC 曲线的锂离子电池内短路早期诊断[J]. 自动化技术与应用, 2026, 45(6): 13-18. (Chen Xian, Lai Sangyu, Mai Yunqiang, et al. Early diagnosis of internal short circuit in lithium-ion batteries based on incremental capacity curves[J]. Techniques of Automation and Applications, 2026, 45(6): 13-18.)

弛豫阶段数据,实时性不足。文献[11]构建二阶 RC 模型,分析电压与 SoC 变化速率一致性实现检测,但该方法对模型参数敏感,难以在老化电池或复杂工况中保持准确性。文献[12]构建电-热耦合模型,通过分析电池运行过程中的电压与表面温度变化特征实现内短路检测,利用 Pearson 相关系数辅助判别 ISC,但该方法需要一定的计算量,实时性受限。文献[13]基于平衡容量的定量分析方法,通过计算电池在无短路条件下的理论平衡容量,并与电池管理系统测得的实际平衡容量进行对比,实现内短路检测与短路电阻估算,该方法无需额外传感器,适用于主动、被动均衡场景,且对负载曲线不敏感,但对电池健康状态 (state of health, SoH) 估算精度存在一定依赖。

近年来,深度学习技术在各个领域得到广泛应用^[14-18],在处理复杂信号和进行智能故障诊断方面展现出巨大潜力。越来越多的研究者开始将其应用于锂离子内短路诊断领域,一类是以 CNN 为代表的方法,如文献[19]利用 CNN 提取电动汽车电池内部缺陷的局部特征,展现其在故障识别中的潜力;文献[20]则通过引入跳跃连接与多尺度卷积结构,增强了模型对复杂特征的表达能力。然而,这类方法主要关注信号的局部结构模式,难以有效捕捉故障演化过程中的时间动态信息。另一类是以长 LSTM 为核心的方法,它善于挖掘时序数据中的长期依赖关系,文献[21]将其用于电池组运行状态的序列建模,文献[22]则结合核主成分分析方法提升了退役动力电池的老化状态识别准确性。但 LSTM 在直接处理原始电压等高维序列时,往往存在特征提取效率不高、易受噪声干扰等局限性。总体而言,现有方法在内短路检测任务中普遍存在局部与全局建模脱节、对噪声鲁棒性差、时空信息耦合能力不足等问题,尚缺乏一种兼具特征敏感性、又能融合空间结构与时序演化信息的统一高效建模框架。

鉴于 IC 曲线对电池内部电化学状态具有较强表征能力,能放大微小异常特征,同时避免直接使用容量数据时存在的累积误差和不一致性问题,本文提出将 IC 曲线作为诊断特征,结合 CNN-LSTM 深度融合模型,发挥 CNN 局部特征提取和 LSTM 时间序列建模优势,提升锂离子电池内短路早期检测性能。本研究得到了广东省基础与应用基础研究基金项目(2023A1515140004)的资助,聚焦于内短路这一关键的内部退化故障,属于项目关于“提取电池外部健康特征与建立数据驱动的老化机制辨析模型”部分的研究内容。

1 锂离子电池内短路实验

为构建神经网络训练及验证数据集,搭建了如图 1 所示的由电池测试系统 (Chroma 17020)、恒温箱、数据记录仪和计算机组成的实验平台。其中,电池测试系统对电池进行充放电测试;恒温箱用来保持恒定的环境温度;数据记录仪对实验样本数据进行采样;计算机的功能包括程序设定和数据存储。实验采用电池外部并联电阻的方法来

模拟早期的内短路故障^[23]。首先将 18650 锂离子电池并联 4 种不同电阻 (200 Ω , 100 Ω , 50 Ω , 20 Ω), 4 种电阻分别代表早期内短路的 4 个阶段,阻值越小则代表电池发生内短路故障越为严重。将不经过任何处理的电池作为健康电池,电池参数如表 1 所示。然后在 25 $^{\circ}\text{C}$ 的实验环境下,以 0.5C 恒流充电条件对 18650 锂电池进行充电测试,在此过程中使用数据记录仪以 1 Hz 采样频率采集电池电压,电池的充电电压曲线如图 2 所示。




图 1 实验平台

Fig. 1 Experimental platform




图 2 并联不同电阻时电池的充电电压曲线

Fig. 2 Charging voltage curves of the battery with different resistors connected in parallel

表 1 电池基本参数

Tab. 1 Basic battery parameters

电池参数	选材取值
额定容量/Ah	3.15
标称电压/V	3.7
截止电压/V	放电:2.5 充电:4.2
阴极材料	Li(NiCoMn)O ₂
阳极材料	石墨

2 锂离子电池增量容量曲线

增量容量曲线是一种常用的分析电池机理的方法,可

以监测相同电压变化范围内的锂离子电池容量变化,进而探索电池内部反应机制在不同充放电阶段的变化^[24]。从数学意义上 IC 曲线是电池容量增量 (ΔQ) 与开路电压增量 (ΔV) 之比,这个比值有效地表示了容量对电压的导数,可以表示^[25]为

$$\frac{dQ}{dV} = \frac{\Delta Q}{\Delta V} = \left| \frac{Q_t - Q_{t-1}}{V_t - V_{t-1}} \right| \quad (1)$$

式中, Q_t 和 V_t 分别为在 t 时刻的电池容量和电压值。

电压间隔 ΔV 对 IC 值有显著的影响, ΔV 过小或过大都可能导致 IC 曲线失真。因此,为了消除曲线中的噪声,需对曲线进行平滑和滤波处理^[26]。在频域中不同频率分量表示信号中对应的频率成分,低频分量通常反映信号的主要趋势或结构,而高频分量对应噪声或快速波动^[27]。通过傅里叶变换将信号转换到频域后,截断或抑制高频分量可以实现信号的平滑处理^[28]。对于一个长度为 N 的离散信号 $x[n]$,离散傅里叶变换的数学表达式为

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-\frac{2\pi i}{N}kn}, k=0,1,2,\dots,N-1 \quad (2)$$

式中, $x[n]$ 是时域信号的第 n 个采样点, $X[k]$ 是频域信号的第 k 个频率分量, N 是信号的采样点数。

虽然离散傅里叶变换能够计算信号的频域信息,但其计算复杂度为 $O(N^2)$,这对于大规模数据处理是非常耗时的。FFT 通过对傅里叶变换进行算法优化,将计算复杂度降低到 $O(N \log N)$,极大地提高了计算效率。FFT 的核心思想是将信号分解为奇数和偶数索引的子序列,分别计算它们的离散傅里叶变换,最后将结果组合在一起^[29]。这一过程可以递归进行,直到每个子序列只包含一个点。FFT 的递归分解公式为

$$X[k] = \sum_{n=0}^{N/2-1} (x[2n] \cdot e^{-\frac{2\pi i}{N}2nk} + x[2n+1] \cdot e^{-\frac{2\pi i}{N}(2n+1)k}) \quad (3)$$

FFT 处理原始 IC 曲线的效果如图 3 所示,实线是原 IC 曲线,虚线是经过 FFT 平滑后的曲线。可见平滑效果较好,可以清晰地分辨出 IC 曲线的峰部,为内短路诊断方法奠定了基础。




图 3 快速傅里叶变换对 IC 曲线进行平滑

Fig. 3 Fast fourier transform for smoothing the IC curve

3 CNN-LSTM 神经网络结构

针对锂离子电池内短路故障的演变特点,设计一种融

合 CNN 与 LSTM 的深度融合诊断模型。IC 曲线作为输入特征,反映电池内部电化学状态的变化过程,特别是短路故障引起的局部容量响应异常和全局趋势变化。因此,模型需要同时具备提取局部特征的能力与捕获动态时间演变规律的能力,以实现早期内短路故障的精准检测。如图 4 所示,采用一维卷积(1D-CNN)对 IC 曲线进行特征提取。IC 曲线通常包含两个主要峰值和若干细微波动,局部峰值形态直接关联于电池内部反应动力学变化与短路程度。通过设置卷积核大小为 2,卷积步长为 1,卷积层可有效捕获这些局部模式变化,增强对短路微特征的敏感性。同时,池化层通过下采样保留主要特征趋势,减少噪声干扰并抑制过拟合。平坦层将 CNN 提取的局部特征编码为一维特征向量,供后续序列建模使用。




图 4 1D-CNN 结构

Fig. 4 Structure of 1D-CNN

LSTM 的结构如图 5 所示,用于捕捉 IC 曲线中的全局趋势及其随短路演变过程的动态变化规律。内短路发生后,电池充电过程中泄漏路径的变化导致 IC 曲线整体趋势和局部峰值随时间和故障程度呈现动态演变特征。LSTM 网络通过门控机制捕获 IC 曲线序列中的长期依赖关系,能够有效学习不同短路阶段下的特征演化模式。此外,LSTM 具备较强的容错能力,对实际采集 IC 曲线中可能存在的噪声波动具有一定的鲁棒性。该网络引入了遗忘门、输入门、输出门和记忆单元,其原理说明如下^[30]。

遗忘门是决定哪些数据丢失,用输出(0 或 1)之间的数据来选择下一刻的电池电压矢量数据,计算公式表示为

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f) \quad (4)$$

式中, f_t 表示遗忘门的输出矢量; W_f 和 U_f 表示线性关系的系数; b_f 表示偏差; x_t 表示当前时刻的电压数据矢量; h_{t-1} 是前一时间步电压数据的变换向量。

输入门确定更新哪些电压数据, \tanh 层创建一个候选存储单元向量,提供给状态门。

$$i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_c h_{t-1} + U_c x_t + b_c) \quad (6)$$

式中, i_t 和 \tilde{C}_t 分别为输入门的输出向量和候选记忆向量; W_i 、 U_i 、 W_c 、 U_c 表示线性关系系数; b_i 和 b_c 代表偏差。

$$C_t = C_{t-1} \odot f_t + i_t \odot \tilde{C}_t \quad (7)$$

式中, C_t 表示存储单元向量, \odot 表示 Hadamard 积。

输出门的作用是输出一个预测当前时刻电压数据的矢量。

$$o_t = \sigma(W_o h_{t-1} + U_o x_t + b_o) \quad (8)$$

$$h_t = o_t \odot \tanh C_t \quad (9)$$

为了实现分类任务,将输出门生成的输出 h_t 经过全连接层和 softmax 层的处理。全连接层的输出量 z 的计算公式为

$$z = W_z h_t + b_z \quad (10)$$

式中, W_z 和 b_z 分别为全连接层的权重矩阵和偏置向量。

Softmax 层将全连接层的输出 z 转换为概率分布 \hat{y}_i 。

Softmax 函数的公式为

$$\hat{y}_i = \frac{\exp z_i}{\sum_{j=1}^n \exp z_j} \quad (11)$$

式中, z_i 是第 i 个类别的全连接层输出量, n 是分类类别的数量。每个类别的 z_i 转换为对应的预测概率 \hat{y}_i , 这些概率值表明输入数据属于各个类别的可能性。

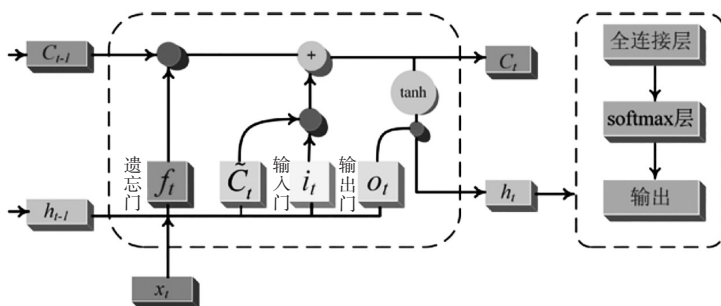


图5 LSTM 结构

Fig. 5 LSTM structure

4 结果与讨论

本研究采集了 5 000 组实验数据,每种内短路严重程度各 1 000 组,保证了各类别样本数量均衡,避免类别不平衡导致模型偏倚。采用 8 : 2 划分训练集与测试集比例,以兼顾模型训练与泛化评估。参考已有文献中类似深度学习在电池诊断中的收敛经验,结合本研究中训练过程中的准确率与损失曲线监测结果,训练次数设置为 500 次,保证模型充分学习特征而不过拟合。

如图 6 所示,根据不通过内短路严重程度的锂离子电池电压数据计算得到其 IC 曲线。IC 曲线呈现两个峰部,一个低谷。随着内短路程度的加深,短路阻值逐渐减小,IC 曲线向上移动。这是由于容量的数据是根据充电时间进行计算,短路产生的泄漏电量消耗了部分能量,使电压产生相同的上升幅度时所需的时间更多,计算得到的容量就更大。而短路阻值越大,消耗的能量就越多,IC 曲线的位置越往上。20 Ω 阻值作为本研究设置的最低阻值,其对应的轨迹明显偏离其余曲线,可将其视为早期和中期内短路的临界值。IC 曲线通过峰值高度、位置和曲线形态的变化,能够提供更多的特征来指示内短路故障的严重性。这些特征为通过数据驱动方法进行内短路故障严重程度检测提供了可靠的依据。

训练和测试过程在配备了 NVIDIA Geforce RTX 3080 的 Tensorflow 2.6.0 平台上进行。使用 Adam 优化器和分类交叉熵损失函数来训练神经网络模型,并采用准确率 (accuracy) 和损失 (loss) 作为评估指标,具体计算方法如式 (12)、(13) 所示。

$$\text{loss} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^c y_{i,c} \log(p_{i,c}) \quad (12)$$




图6 不同内短路程度下的 IC 曲线

Fig. 6 IC curves at different degrees of internal short-circuiting

$$\text{accuracy} = \frac{\text{TP}}{N} \quad (13)$$

式中, N 表示样本总数, C 表示类别总数, $y_{i,c}$ 表示样本 i 的真实类别 c 是否为 1 (one-hot 编码), $p_{i,c}$ 表示模型预测样本 i 属于类别 c 的概率, TP 表示预测正确的样本数目。

首先选取无故障样本 800 个和随机均匀抽取 4 种故障样本 (200 Ω 、100 Ω 、50 Ω 、20 Ω) 各 200 个,分为“无故障”和“故障”两类 (每类 800 个样本),验证模型对于内短路的检测能力。然后对所有的 5 000 个样本进行训练,验证模型对不同内短路程度的诊断能力。训练集和测试集按 8 : 2 进行设置,训练次数设置为 500 次,每 10 次训练结束则计算一次准确度和损失的值。图 7 展示两种训练过程的准确度曲线趋势。两个过程都呈上升趋势,后期都趋于收敛。在两种分类方式下,模型的最终准确率都接近 90%。对于 5 类别的分类过程,训练和测试准确率分别达到 88.62% 和 86.46%。该模型不论是对于故障检测,还是故障程度分类,均具有较高的准确性。




图7 神经网络训练结果

Fig.7 Neural network training results

CNN-LSTM 模型在经过上述 5 个类别训练完成后,从每个类别中随机均匀抽取 200 个样本,验证模型对于不同类别的准确度。图 8 显示模型对抽取的 1 000 个样本进行分类的结果。无故障和 20 Ω 样本的准确率高于 90%, 50 Ω 样本的准确率最低,只有 81.5%。20 Ω 样本的特征最为显著,神经网络容易将其区分,因此其准确率最高。所有类别准确率平均值为 87.7%,与训练结果较为接近,模型具有较好的泛化能力。

CNN 和 LSTM 更好,而相同网络模型下,以 IC 曲线作为输入,其准确率更高。曲线准确率接近。

为了进一步验证该模型的优越性,图 9 展示 3 种不同神经网络模型(CNN-LSTM、1DCNN 和 LSTM)和两种输入(电压数据、IC 曲线)在训练过程中的准确率和损失变化情况。模型准确率在前 100 次训练中有一个快速上升的过程,随后提升速度减缓直到趋于平稳。不同模型最终的收敛水平有所差异,相同输入时,CNN-LSTM 的性能比




图8 不同类别的分类结果

Fig.8 Classification results for different categories

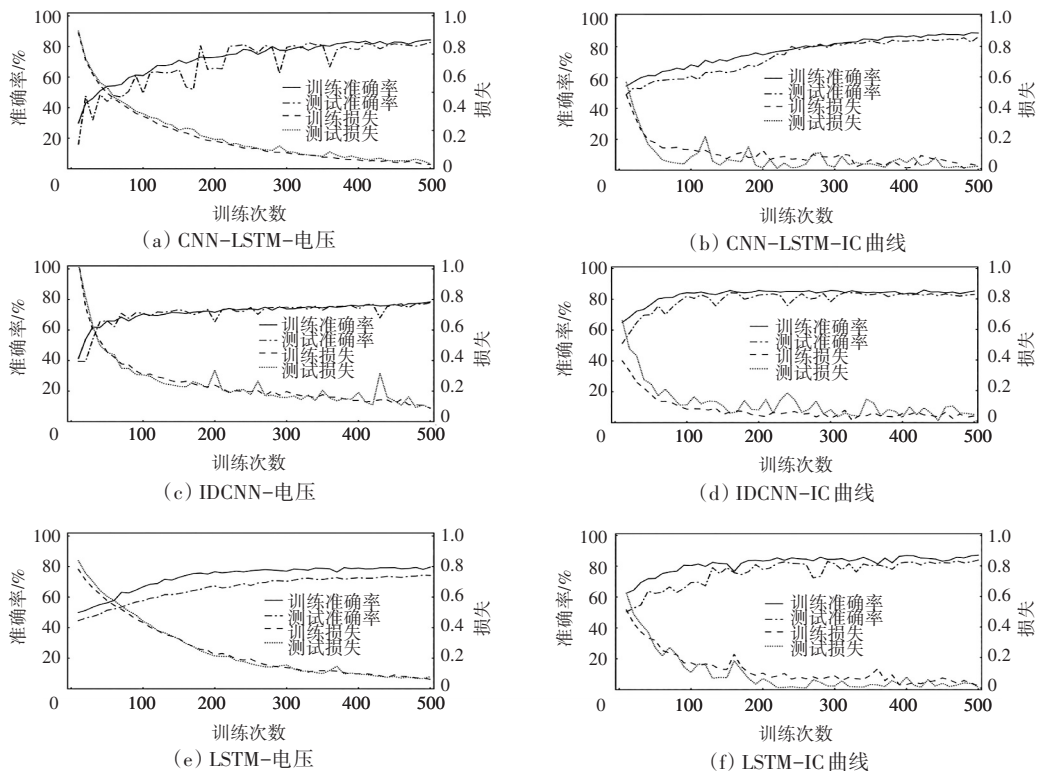


图9 不同网络训练过程的准确率和损失变化

Fig.9 Variation of accuracy and loss for different network training processes

5 结论

针对锂离子电池内短路故障的早期诊断需求,提出了一种基于IC曲线特征与CNN-LSTM混合架构的诊断模型。该方法通过引入IC曲线增强了电压微小异常特征的可辨识性,并利用CNN-LSTM架构结合局部特征提取与全局动态建模能力,提升了对故障程度的诊断精度。对比实验结果表明,该模型在5类别内短路故障诊断任务中,训练准确率达88.62%,测试准确率达86.46%。该模型不仅显著优于单独的1DCNN或LSTM模型,其训练与测试准确率的高度一致性也证明了其良好的泛化能力。综上,本研究为锂离子电池早期故障诊断提供了一种经过实验验证的有效手段。未来工作将围绕提升模型的实时性与鲁棒性,探索其在其他故障类型中的应用潜力展开,以拓展其在电池管理系统中的实际价值。

参考文献

- [1] 黎钦懿, 杨林, 羌嘉曦. 融合内部温度估计的锂电池内短路建模与诊断[J]. 机电一体化, 2021, 27(4):31-40.
- [2] 崔志仙, 王青松, 孙金华. 锂枝晶导致的锂离子电池内短路模拟研究[J]. 火灾科学, 2019, 28(2):101-112.
- [3] 耿莉敏, 赵扬, 高楠, 等. 锂离子电池内短路形成机理及检测方法综述[J]. 汽车工程学报, 2023, 13(4):481-495.
- [4] Xin L, Changyong J, Wei Y, et al. Mechanism, modeling, detection, and prevention of the internal short circuit in lithium-ion batteries; recent advances and perspectives[J]. Energy Storage Materials, 2021(35):470-499.
- [5] Qi X, Liu B, Pang J, et al. Unveiling micro internal short circuit mechanism in a 60 Ah high-energy-density Li-ion pouch cell[J]. Nano Energy, 2021(84):105908.
- [6] Kong X, Zheng Y, Ouyang M, et al. Fault diagnosis and quantitative analysis of micro-short circuits for lithium-ion batteries in battery packs[J]. Journal of Power Sources, 2018(395):358-368.
- [7] Yao Y, Du X, Jiang S, et al. Prognostics of internal short circuit in lithium-ion batteries—Literature survey and performance evaluation[J]. Journal of Power Sources, 2025(648):237203.
- [8] 耿莉敏, 赵扬, 高楠, 等. 锂离子电池内短路形成机理及检测方法综述[J]. 汽车工程学报, 2023, 13(4):481-495.
- [9] Tao J, Wang S, Cao W, et al. An innovative multitask learning—Long short-term memory neural network for the online anti-aging state of charge estimation of lithium-ion batteries adaptive to varying temperature and current conditions[J]. Energy, 2025(314):134272.
- [10] 丘恒越, 田凌, 旷永红. 基于弛豫电压的锂离子电池内短路分级检测方法[J]. 广东电力, 2024, 37(7):32-41.
- [11] 李志强, 刘杰, 陈慧, 等. 基于神经网络的电池故障诊断与预测[J]. 电池工业, 2018, 23(4):78-82.
- [12] Pan T, Yu Z, Ma S, et al. Detection of internal short circuit in lithium-ion batteries based on electrothermal coupling model[J]. Journal of Energy Storage, 2025(106):114685.
- [13] Lai X, Ke Y, Tang X, et al. Balanced capacity-based quantitative method for detecting internal short circuits in lithium-ion battery modules[J]. Journal of Energy Storage, 2025(123):116622.
- [14] 咎楠楠. 基于全局CNN与局部LSTM的国画图像分类算法[J]. 自动化技术与应用, 2024, 43(4):115-117.
- [15] 王冰梅, 张冶, 李书斌, 等. 基于CNN-LSTM混合网络的新型配电网异常数据检测模型[J]. 太阳能学报, 2025, 46(5):243-250.
- [16] 王飞. 基于改进CNN卷积神经网络的音乐识别模型构建[J]. 自动化技术与应用, 2024, 43(2):127-131.
- [17] 高振华, 秦奋起, 王琳琳, 等. 基于改进CNN-LSTM的开关门故障诊断方法[J]. 兵工学报, 2025, 46(9):51-60.
- [18] 张莉, 李承桓, 秦美翠, 等. 基于LSTM网络优化的电力客服语音情感识别系统[J]. 自动化技术与应用, 2025, 44(10):66-69.
- [19] 边楠, 耿兆杰, 张永跃, 等. 基于CNN探测电动汽车电池内部缺陷分析[J]. 北京汽车, 2022(3):39-42.
- [20] 吴诗淼, 王文波, 朱婷, 等. 基于跳跃连接多尺度CNN的锂离子电池剩余寿命预测[J]. 太阳能学报, 2024, 45(7):199-208.
- [21] 李轩谊, 赵慧勇. 基于LSTM的电池组工作状态预测[J]. 湖北汽车工业学院学报, 2023, 37(4):22-26, 31.
- [22] 黄志礼, 蔺红. 基于LSTM与KPCA的退役动力电池分选方法[J]. 国外电子测量技术, 2023, 42(12):152-159.
- [23] 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 Transaction on Industrial Electronics, 2019, 66(3):2132-2142.
- [24] Zhao X, Wang J, Zhao M, et al. Micro-short circuit fault diagnosis of the parallel battery module based on increment capacity curve[J]. Journal of Energy Storage, 2024(86):111201.
- [25] Xu Z, Chen Z, Yang L, et al. State of health estimation for lithium-ion batteries based on incremental capacity analysis and Transformer modeling[J]. Applied Soft Computing, 2024(165):112072.
- [26] Zhang Y, Liu Y, Wang J, et al. State-of-health estimation for lithium-ion batteries by combining model-based incremental capacity analysis with support vector regression[J]. Energy, 2022(239):121986.
- [27] Chen H, Yue W, Bin G, et al. Filter methods comparison for incremental capacity analysis in lithium-ion batteries health prediction[J]. Journal of Energy Storage, 2024(101):113878.
- [28] Cheng F, Liu H, Lyu X. Lithium-ion batteries remaining useful life prediction via Fourier-mixed window attention enhanced Informer with decomposition and adaptive error correction strategy[J]. Advanced Engineering Informatics, 2025(65):103292.
- [29] Liu Z, Ruan G, Tian Y, et al. Application of a transformer network based on multi-scale branches and fast Fourier gating mechanism in the state of charge prediction for sodium-ion batteries[J]. Expert Systems with Applications, 2025(285):127931.
- [30] Bao G, Liu X, Zou B, et al. Collaborative framework of transformer and LSTM for enhanced state-of-charge estimation in lithium-ion batteries[J]. Energy, 2025(322):135548.