



融合小波与 MS-TCN 的锂电池热失控自适应预警

吴文进, 沙 晗, 郑鹏贤, 詹文法, 吴 晶

(安庆师范大学电子工程与智能制造学院, 安徽 安庆 246133)

摘 要: 针对锂离子电池热失控早期微短路 (ISC) 信号极易被动态负载与环境噪声掩盖, 以及传统固定阈值法在复杂工况下面临严重“报警疲劳”与漏报的难题, 设计并验证了一种融合小波特征增强、多尺度时域卷积网络 (MS-TCN) 与自适应阈值的早期预警方法。首先, 分析了微短路演化过程中的多维物理特征, 针对初期电压跌落特征不明显的缺陷, 构建了物理信息增强的特征工程; 选用具有二阶消失矩与良好平滑性的 db4 小波基, 对电压信号进行 3 层离散小波分解, 通过提取高频细节能量并耦合表面温度趋势, 显著增强了微弱故障信号在强噪声背景下的信噪比。其次, 构建了基于指数增长膨胀因果卷积的 MS-TCN 架构, 利用其线性计算复杂度与超大感受野优势, 替代传统 LSTM 网络, 实现了对电压秒级瞬态突变与温度分钟级热积累趋势的并行捕捉, 建立了高精度的电池正常行为预测基准。进而, 提出了基于指数加权移动平均 (EWMA) 的自适应决策策略, 摒弃固定阈值, 根据预测残差的实时统计特性动态调整报警边界 (灵敏度系数 $k=3$), 实现了对异常的连续性判定。实验结果表明: 基于欧盟 JRC 感应加热热失控数据集的验证显示, 该方法在同构软包电池上的 $F1$ 分数高达 0.9784, 平均提前预警时间约为 29 s; 与 Transformer 及 CNN 模型相比, $F1$ 分数分别提升了 8.68% 和 9.15%, 且计算效率更高。研究还发现, 在跨封装类型 (软包迁移至圆柱) 的少样本场景下, 本方法仍保持 0.9554 的 $F1$ 分数与零误报率。结论指出, 本方法摆脱了对电流传感器的依赖, 有效解决了宽温域工况下误报与漏报难以平衡的问题, 为电动汽车与储能电站的安全监控提供了高鲁棒性的解决方案。

关键词: 热失控预警; 早期异常检测; 多尺度时域卷积网络; 小波变换; 自适应 EWMA 阈值

doi: 10.19799/j.cnki.2095-4239.2026.0019

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2026) 08-3143-10

Adaptive thermal runaway early warning for Li-ion batteries via wavelet and MS-TCN fusion

WU Wenjin, SHA Han, ZHENG Pengxian, ZHAN Wenfa, WU Jing

(School of Electronic Engineering and Intelligent Manufacturing, Anqing Normal University, Anqing 246133, Anhui, China)

Abstract: Early internal short circuit (ISC) signals in Li-ion batteries are easily masked by dynamic loads and environmental noise, which subjects traditional fixed-threshold methods to severe "alarm fatigue" and missed detections under complex conditions. To address these challenges, this study designed and validated an early warning framework fusing wavelet feature enhancement, a multi-scale temporal convolutional network (MS-TCN), and adaptive thresholding. First, the multidimensional physical characteristics during ISC evolution were

收稿日期: 2026-01-08; 修改稿日期: 2026-02-01。

基金项目: 国家自然科学基金重大研究计划项目 (92573109), 国家自然科学基金面上项目 (62474002), 安徽高校协同创新项目 (GXXT-2021-025)。

第一作者及通信联系人: 吴文进 (1975—), 男, 博士, 教授, 研究方向为电力电子系统及其控制、电能储存与节电技术, E-mail: wuwenjinaq@163.com。

引用本文: 吴文进, 沙晗, 郑鹏贤, 等. 融合小波与 MS-TCN 的锂电池热失控自适应预警[J]. 储能科学与技术, 2026, 15(8): 3143-3152.

Citation: WU Wenjin, SHA Han, ZHENG Pengxian, et al. Adaptive thermal runaway early warning for Li-ion batteries via wavelet and MS-TCN fusion[J]. Energy Storage Science and Technology, 2026, 15(8): 3143-3152.

analyzed. A feature engineering approach enhanced with physical information enhancement was constructed to address unobvious initial voltage drops. Specifically, the Daubechies 4 wavelet base, characterized by a second-order vanishing moment and good smoothness, was selected to perform a three-level discrete wavelet decomposition on the voltage signals. Extracting the high-frequency detail energy and coupling it with surface-temperature trends significantly improved the signal-to-noise ratio of weak fault features under intense background noise. Second, an MS-TCN architecture based on exponentially increasing dilated causal convolutions was developed. This model, leveraging its linear computational complexity and extensive receptive field, was employed instead of traditional long short-term memory networks to simultaneously capture transient voltage mutations (seconds scale) and thermal-accumulation trends (minutes scale), establishing a high-precision baseline for normal battery behavior. Furthermore, an adaptive decision strategy based on exponentially weighted moving averages was proposed. By dynamically adjusting alarm boundaries based on the real-time statistical properties of prediction residuals (sensitivity coefficient = 3), this strategy achieved continuous anomaly determination without relying on fixed thresholds. Experimental results on the European Commission Joint Research Centre dataset demonstrate that the proposed method achieved an $F1$ -score of 0.9784 on pouch cells, providing an average warning lead time of approximately 29 s. Compared with transformer and convolutional neural network models, the $F1$ -scores were improved by 8.68% and 9.15%, respectively, while exhibiting higher computational efficiency. Crucially, in cross-package transfer scenarios (from pouch to cylindrical cells) comprising limited samples, the method maintained an $F1$ -score of 0.9554 and a zero-false-alarm rate. In conclusion, this method eliminated the dependency on current sensors and effectively resolved the trade-off between false alarms and missed detections across wide temperature ranges, providing a highly robust solution for safety monitoring in electric vehicles and energy storage stations.

Keywords: thermal runaway early warning; early anomaly detection; multi-scale temporal convolutional network (MS-TCN); wavelet transform; adaptive EWMA threshold

锂离子电池作为电化学储能与交通电动化的核心载体,其高比能量体系的应用带来了显著安全隐患。研究表明,热失控(thermal runaway, TR)往往是由内部微短路(internal short circuit, ISC)等诱发的渐进式恶化过程。在热失控早期,伴随的微弱电压压降及局部温升极易被动态工况与环境噪声掩盖,导致故障识别极其困难^[1-2]。研究表明,从微短路发生到电池单体热失控往往存在一个极短的“黄金逃生窗口”,一旦错过该阶段,电池内部的链式放热反应将变得不可逆转。据统计,现有的BMS策略在面对复杂动态工况时,往往在热失控发生的数秒前才发出警报,留给乘员逃生或系统消防介入的时间严重不足。因此,如何在强噪声背景下抢在热失控临界点之前精准捕捉微弱前兆信号,

已成为当前电池安全领域的“卡脖子”难题。

目前,故障诊断主要分为机理模型、信号阈值和数据驱动三类方法。机理模型依赖参数辨识,易受电池老化与模型失准影响,且难以在算力受限的电池管理系统中实时运行^[3]。工程主流的固定阈值法虽简单,但面临“两难”困境:阈值过宽易漏报,过窄则在宽温域动态工况下引发严重的“报警疲劳”问题。

随着数据驱动技术的发展,学者开展了广泛研究。文献[4]从机械特性出发,分析膨胀与内短路阻值的关联,提出了基于耦合机械应力的检测方法;文献[5]设计了基于非冗余交错测量电路与改进模糊熵(improved fuzzy entropy, IFuzzyEn)的策略,实现了对故障类型和程度的定位;文献[6]利用高斯

混合模型挖掘充电大数据统计特征，降低了复杂工况下的误报率。针对电压信号的时序特性，文献[7]利用小波时频图结合图像熵与聚类算法识别异常；文献[8]构建数字孪生框架，结合时域卷积网络（temporal convolutional network, TCN）与长短期记忆网络（long short-term memory, LSTM）并通过迁移学习提升状态估计精度；文献[9]设计合成热卷积-记忆网络，融合 TCN 并行计算与 LSTM 记忆能力以提升抗噪性能。此外，文献[10]全面综述了 BMS 中的高级算法，指出虽然人工智能等数据驱动策略在故障诊断方面取得了显著进展，但在热失控等高危场景下，如何平衡算法的高精度与 BMS 有限算力之间的矛盾，仍是当前亟待解决的关键难题。

然而，针对热失控早期预警任务，现有模型仍面临挑战：传统 LSTM 处理超长序列时易遭遇梯度消失与串行效率低的问题^[11]；而故障特征兼具秒级突变与分钟级热积累的多尺度特性。尽管 Transformer 在长序列预测上表现优异，但其二次方计算复杂度难以适配成本敏感且算力受限的电池管理系统（battery management system, BMS）芯片。相比之下，时域卷积网络（TCN）通过空洞卷积在保持线性计算复杂度的同时，能获得指数级增长的感受野，是当前算力约束下实现长序列高精度建模的最佳平衡点^[12]。

针对上述挑战，本研究提出一种融合小波特征增强、多尺度时域卷积网络（multi-scale temporal convolutional network, MS-TCN）与自适应阈值的锂电池热失控早期预警方法。首先，构建物理信息增

强的特征工程：采用原始电压，联合电池温度特征剔除热噪声，并利用离散小波变换（DWT）增强由微短路诱发的微弱电压跌落特征^[13]。在此基础上，设计基于指数级增长空洞卷积的 MS-TCN 模型，并行捕捉秒级瞬态突变与分钟级演化趋势，建立电池正常行为基准。最后，摒弃固定阈值，设计基于指数加权移动平均（exponentially weighted moving average, EWMA）的动态阈值策略，根据预测误差实时统计特性自适应调整报警边界，在保证高灵敏度的同时有效解决宽温域工况下的误报问题。

1 锂电池热失控预警方法设计

1.1 总体架构

本研究提出的锂离子电池热失控早期预警方法总体框架如图 1 所示。针对储能电站静置或电动汽车驻车等“零负载”高危场景，由于缺乏电流激励且初期热特征不明显，单一维度的电压或温度监测难以有效区分传感器噪声与微短路信号。为此，本研究构建了包含多维特征构建与预处理、MS-TCN 时序建模及自适应阈值决策的三阶段预警架构。首先，在特征工程阶段，摒弃了对电流及环境温度的依赖，直接利用离散小波变换（DWT）挖掘电压信号中的高频奇异特征，并结合单点表面温度趋势，构建多维状态向量；其次，利用多尺度时域卷积网络（MS-TCN）特有的指数增长膨胀因果卷积结构，并行捕捉电压的瞬态突变与长期演化规律，建立正常工况下的高精度预测基准；最后，通过基于 EWMA 的自适应阈值策略分析预测残差，实现对热失控早期异常的敏锐捕捉与零误报输出。

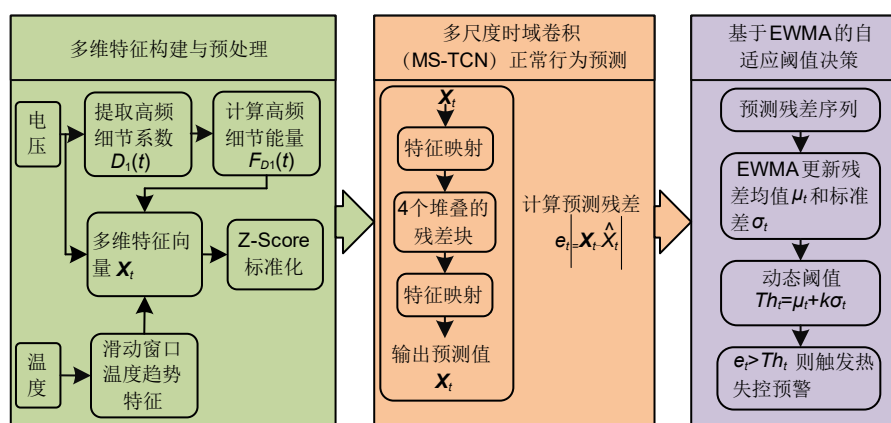


图 1 整体框架

Fig. 1 Architecture framework

1.2 多维特征增强与输入向量构建

电池热失控早期的微短路 (ISC) 信号具有“弱信号、强噪声、瞬态性”的特点。在静置或恒压浮充工况下, 端电压的变化极其微小 (毫伏级), 极易被 BMS 的量化噪声或电化学弛豫过程所掩盖。直接将原始传感器数据输入神经网络, 往往因信噪比过低导致模型收敛困难。因此, 本研究从时频分析与多物理量融合的角度出发, 构建包含原始电压、小波增强特征及表面温度的多维特征向量, 以提升故障特征的显著性^[14]。

首先, 内短路发生初期, 电压曲线通常伴随毫伏级的毛刺或瞬态降压, 这些高频奇异点在时域上极易被大幅度的充放电电压掩盖。离散小波变换 (DWT) 具备多分辨率分析能力, 能够将非平稳信号分解为不同频带的子信号。

本研究选用具有紧支集与正交性 (daubechies 4, db4) 小波基, 对原始电压信号 $V(t)$ 进行 $J=3$ 层分解与重构。选择 db4 小波基的理论依据主要在于其正则性与紧支集长度之间的最优平衡: 相比于不连续的 Haar 小波, db4 具有二阶消失矩和更好的平滑性, 能够更精准地匹配微短路引发的非突变式电压跌落特征, 避免信号截断产生的虚假高频伪影; 而相比于 db6 或 db10 等高阶小波, db4 的滤波器长度较短 (8 个系数), 在保证特征提取精度的同时极大地降低了卷积运算量, 并减少了实时处理时的边界效应, 更契合在线预警对实时性的严苛要求。

根据小波多分辨率分析理论, 原始信号可表示为各频带重构信号的线性叠加:

$$V(t) = A_J(t) + \sum_{j=1}^J D_j(t) \quad (1)$$

式中, $A_J(t)$ 为低频近似系数, 反映电压的整体趋势; $D_j(t)$ 为第 j 层的高频细节系数。由于微短路特征主要集中在高频段, 本研究提取第一层细节重构信号 $D_1(t)$, 并计算其滑动均方根值作为高频增强特征 $F_{D1}(t)$:

$$F_{D1}(t) = \sqrt{\frac{1}{\omega} \sum_{k=t-\omega+1}^t [D_1(k)]^2} \quad (2)$$

式中, ω 为滑动窗口长度, $D_1(k)$ 为滑动窗口内第 k 个采样点处第一层细节重构信号的幅值。

其次, 引入电池表面温度趋势作为辅助特征。虽然热失控早期由微短路引发的温升幅度较小, 但

温度作为热失控发生的最终物理表征, 提供了区别于电压信号的独立观测维度。在缺乏环境温度参考的情况下, 单一的电池表面温度依然包含了热积累的关键信息。不同于电压信号的瞬间跌落, 温度信号具有显著的热惯性, 呈现出积分性质的长期演化趋势。引入表面温度特征, 能够辅助模型学习正常工况下的“电压-温度”稳态约束关系。当发生内短路时, 即使电压跌落微弱, 伴随的异常热积聚也会破坏原有的稳态关系, 从而在多维特征空间中产生可识别的偏移。

综合上述分析, 针对 t 时刻, 本研究构建的多维模型输入向量定义如式(3)所示。为了消除不同物理量纲 (电压、温度、小波系数) 的数量级差异对神经网络梯度下降的影响, 采用 Z-Score 标准化方法对数据进行预处理, 使其符合标准正态分布 $N(0, 1)$ 。

$$\mathbf{X}_t = [V(t), T(t), F_{D1}(t)]^T \quad (3)$$

该特征组合摒弃了对负载电流的依赖, 直接利用 MS-TCN 强大的时序上下文建模能力, 在多维特征空间中学习正常工况下的电压-小波-温度演化流形。当发生异常时, 无论是在电压的瞬态高频域, 还是温度的长期趋势域, 只要偏离了正常流形, 均会被模型识别为异常残差, 从而实现高精度的早期预警。

2 多尺度时域卷积网络架构

为了解决传统 LSTM 网络在处理长序列时存在的梯度消失与串行计算效率低的问题, 并在统一框架下同时刻画电压瞬态突变 (秒级) 与热演化趋势 (分钟级) 的多尺度特征, 本研究构建了基于膨胀因果卷积的多尺度时域卷积网络 (MS-TCN)。网络以上文构建的物理增强型多维特征向量为输入, 在仅利用正常工况数据进行训练的前提下, 建立“电池正常行为”的时序预测基准, 为后续基于残差的异常检测提供支持。多尺度时域卷积网络架构如图 2 所示。

2.1 因果空洞卷积

TCN 的核心在于结合因果约束与空洞卷积。所谓因果性, 是指 t 时刻的预测输出仅依赖于 t 时刻及之前的历史信息, 严格避免利用任何来自未来的样本, 从而满足在线预警场景对实时性和可实现性的要求^[15-16]。空洞卷积则通过在卷积核中插入“空洞”来扩大感受野。设卷积核大小为 K , 膨胀率为 d ,




图 2 多尺度时域卷积网络 (MS-TCN) 架构示意图

Fig. 2 Architecture of the multi-scale temporal convolutional network

对输入序列 X 的第 s 个位置，空洞卷积运算定义为：


$$F(s) = (X *_{\text{d}} f)(s) = \sum_{i=0}^{K-1} f(i) \cdot x_{s-di} \quad (4)$$

式中， $X=\{x_i\}$ 为输入的一维特征序列； $f(i)$ 为一维卷积核的第 i 个权重系数，卷积核长度为 K ； d 为空洞卷积的膨胀率 (dilation rate)，即相邻两个卷积核采样点在输入序列上的间隔为 d 个时间步；符号 $*_{\text{d}}$ 表示膨胀率为 d 的一维离散卷积运算。通过在时间维度左侧进行适当的零填充，保证输出序列长度与输入一致。

当在网络中堆叠 L 层空洞卷积时，若记第 L 层 ($1 \leq l \leq L$) 的膨胀率为 d_l ，且使其按指数级增长 (即 $d_l = 2^{l-1}$ 时)，则网络第 L 层输出单元的感受野大小 R 可计算为：

$$R = 1 + (K - 1) \sum_{l=1}^L d_l \quad (5)$$

该特性使得网络可在较浅的深度下覆盖数百至数千个时间步的历史信息。如图 3 所示，以卷积核大小 $K=3$ 为例，当膨胀率 d 随层数呈 1, 2, 4 指数增长时，顶层输出节点通过红色高亮路径能够有效回溯并覆盖底层的长跨度输入数据。这种树状结构直观地展示了模型如何在保持计算复杂度呈线性的前提下，大幅扩展时序感受野。这一特性对于锂电池热失控建模至关重要：模型既能够敏锐感知秒级的电压高频毛刺，又能同步兼顾分钟级的温升与内阻变化等缓慢动态过程。

图 3 基于膨胀因果卷积的感受野增长示意图 ($K=3$)Fig. 3 Schematic diagram of receptive field growth based on dilated causal convolution ($K=3$)

2.2 残差连接与网络架构

为提升深层网络的训练稳定性并进一步增强长序列建模能力，本研究在 TCN 基础上引入残差连接^[17]。假设在 t 时刻之前的长度为 L 的滑动时间窗内，输入特征维度为 C_{in} ，记该时间窗内的特征矩阵为 $X_{t-L+1:t} \in \mathbb{R}^{L \times C_{in}}$ 。

首先利用一层 1×1 卷积将输入特征映射到统一的隐藏维度 C_h ：

$$H^{(0)} = \text{Conv}_{1 \times 1}(X_{t-L+1:t}) \in \mathbb{R}^{L \times C_h} \quad (6)$$

在此基础上，MS-TCN 由 4 个堆叠的残差块 (residual block) 组成。每个残差块内部包含两层膨胀因果卷积^[18]、权重归一化 (weight normalization, WN)、ReLU 激活函数以及 Dropout 层。第 b 个残差块的前向传播过程可表示为：

$$\tilde{H}^{(b)} = \text{ReLU} \left\langle \text{WN} \left\{ \text{Conv}_{d_{2b-1}} [H^{(b-1)}] \right\} \right\rangle \quad (7)$$

$$\hat{H}^{(b)} = \text{ReLU} \left\langle \text{WN} \left\{ \text{Conv}_{d_{2b}} \left\{ \text{Dropout} [\tilde{H}^{(b)}] \right\} \right\} \right\rangle \quad (8)$$

式中, $\tilde{H}^{(b)}$ 表示第一层膨胀卷积后的中间激活特征; $\hat{H}^{(b)}$ 表示第二层膨胀卷积后残差分支的最终输出。Conv_d 表示膨胀率为 d 、卷积核大小为 K 的一维因果卷积。为保证梯度传导顺畅, 引入残差连接:

$$H^{(b)} = H^{(b-1)} + S^{(b)}[\hat{H}^{(b)}] \quad (9)$$

式中, $S^{(b)}$ 表示第 b 个残差块的残差映射函数。当残差分支输出与输入通道数一致时, $S^{(b)}$ 为恒等映射, 否则为一个 1×1 因果卷积, 用于线性投影以匹配维度, 确保残差连接的可加性。

为了在有限深度内获得足够大的感受野, 8层卷积的膨胀率按指数级设置为 $\{1, 2, 4, 8, 16, 32, 64, 128\}$, 卷积核大小统一为 $K=3$ 。在该配置下, 网络整体感受野可覆盖 $R \approx 1+2 \times (1+2+\dots+128)=511$ 个时间步 (或更多, 取决于具体层数), 有效覆盖了多尺度动态特征。

经过 B 个残差块后, 取时间窗末端 (即时刻 t) 对应的隐藏状态, 通过输出层还原为预测向量 $\hat{X}_t$ 。网络采用均方根误差作为损失函数, 仅在正常工况样本上进行训练:

$$L_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{t=1}^N (\mathbf{X}_t - \hat{\mathbf{X}}_t)^2} \quad (10)$$

式中, N 为参与损失计算的样本总数。

3 基于 EWMA 的自适应阈值决策策略

由于电池在宽温域以及不同倍率工况下的动态特性差异显著, 传统固定阈值方法极易导致误报或漏报。为此, 本研究提出基于指数加权移动平均 (EWMA) 的自适应阈值决策策略。

3.1 预测残差统计特性分析

定义 t 时刻的预测残差 $\mathbf{e}_t$ 为

$$\mathbf{e}_t = |\mathbf{X}_t - \hat{\mathbf{X}}_t| \quad (11)$$

EWMA 通过对历史残差进行加权平均, 使近期数据获得更高权重, 从而能够快速响应工况的动态变化^[19]。

残差序列的局部均值 μ_t 与方差 σ_t^2 的递推形式分别为:

$$\mu_t = \lambda \mathbf{e}_t + (1 - \lambda) \mu_{t-1} \quad (12)$$

$$\sigma_t^2 = \lambda (\mathbf{e}_t - \mu_{t-1})(\mathbf{e}_t - \mu_t) + (1 + \lambda) \sigma_{t-1}^2 \quad (13)$$

式中, λ 为平滑因子, $0 < \lambda \leq 1$, 决定统计量

的更新速率。 λ 越大, 阈值对当前波动的敏感度越高。

3.2 动态阈值生成与报警逻辑

基于上述统计量, 构建自适应报警阈值 Th_t :

$$Th_t = \mu_t + k \sigma_t \quad (14)$$

式中, k 为灵敏度系数, 用于调节异常判定的置信区间, 以适应不同电池系统的噪声水平。

为抑制传感器瞬态噪声或电磁干扰引发的误报, 本研究引入时间窗口校验机制, 不再单纯依赖单点阈值越限进行判定。系统采用连续性触发逻辑: 仅当异常评分 $\mathbf{e}_t$ 连续 M 个时间步均高于动态阈值 Th_t 时, 才认定电池进入异常状态并触发热失控预警; 反之, 若越限行为持续时间不足 M 个时间步, 则视为随机扰动被系统滤除。该策略在保证对不可逆故障高召回率的同时, 显著增强了检测系统的鲁棒性^[20]。

4 实验验证

为全面评估本方法的有效性与鲁棒性, 实验选用欧盟联合研究中心 (JRC) 公开的锂离子电池感应加热热失控数据集进行验证^[21]。该数据集通过 6 kW 感应加热器配合特定几何形状线圈, 向电池内部注入约为其总能量 1% 的短时热脉冲 (持续 1~4 s), 利用交变电磁场在电池内部金属层诱导涡流, 精准模拟了由内部微短路 (ISC) 引发的热失控渐进演变过程。实验采样频率高达 2 kHz, 能够有效捕捉微短路初期毫伏级的电压高频振荡及多点温度变化, 为早期预警提供了丰富且真实的高频特征信号。实验对象涵盖不同封装与化学体系的商用电池, 具体包括 Test4 与 Test5 (39 Ah NMC 软包电池) 以及 Test3 (3.1 Ah 18650 NMC 圆柱电池)。所有测试均在零负载静置模式下进行, 旨在模拟电动汽车驻车或储能系统待机等高危“静默”场景。实验基于 PyTorch 深度学习框架实现, 在数据预处理阶段, 训练集选取前 1000 个健康样本 (步长 stride=5), 测试集包含剩余全量数据 (步长 stride=1)。模型核心超参数设定为: 滑动窗口长度 50, 批量大小 256, 初始学习率 10^{-3} , 训练轮次 30。评价指标采用精确率 (precision)、F1 分数及物理提前预警时间 (lead time), 预警窗口设定为热失控发生前 30 s。

4.1 不同电池类型的迁移验证

针对实际应用中目标电池故障数据匮乏的“零样本”或“小样本”困境，本研究设计了严格的迁移学习实验以验证模型的泛化能力。实验策略为仅利用数据量充足的 Test4（源域）全量健康数据训练模型，直接在未参与训练的 Test3 和 Test5（目标域）上进行推理测试，并选取 EWMA 阈值灵敏度系数 $k=3$ 。

实验结果表明（表 1），所提方法在同类型的软包电池（Test4 和 Test5）上表现卓越， $F1$ 分数分别达到 0.9784 和 0.9656，提前预警时间稳定在 29 s 以上。这证实了在同类电池迁移场景下，模型能够通过多尺度特征有效捕捉微弱异常，Recall 分别高达 0.9578 和 0.9335。Test5 的 $F1$ 分数略有下降，主要归因于不同单体间热失控严重程度的变异性导致残差分布产生轻微偏移。

表 1 所提方法在不同电池类型上的性能

Table 1 Performance of the proposed approach across various battery types

数据集	Precision	Recall	$F1$ -score	Lead time/s
Test3	1.000	0.9146	0.9554	12.96
Test4	1.000	0.9578	0.9784	29.84
Test5	1.000	0.9335	0.9656	29.63

为了进一步剖析模型在跨工况迁移下的早期预警机制，本研究选取 Test5 测试集进行了全过程可视化分析，如图 4 所示。




图 4 Test5 热失控预警过程可视化

Fig. 4 Visualization of the thermal runaway early warning process for Test 5

由图 4(a)可知，在热失控发生的临界点之前，电池端电压（黑实线）与表面温度曲线（蓝虚线）均保持平稳，肉眼难以察觉异常，极易被传统 BMS 策略忽略。然而，图 4(b)清晰地展示了本方法的优势：得益于小波特征增强与 MS-TCN 对时序突变的敏感性，模型预测残差（紫实线）准确反映了潜在的微短路演变。特别是图 4(b)中的局部放大视图（zoom-in）揭示了关键细节：在测试初期的 $t=0$ s 至 $t=4$ s 区间内，尽管宏观残差幅值远小于后期热失控阶段，但其产生的高频震荡已显著且连续地突破了 EWMA 自适应阈值（红虚线）。值得指出的是，此时的报警信号并非偶发的瞬态噪点，而是呈现出高密度的连续触发特征，这与随机电磁干扰造成的孤立波形截然不同，符合微短路故障持续恶化的物理规律。这种机制确保了系统能够在不可逆的热失控发生前约 29 s 即发出“首次报警（first alarm）”，有效避免了漏报。

此外，在跨封装类型迁移至 Test3（18650 圆柱电池）时，模型仍保持了 0.9554 的高 $F1$ 分数，验证了其强大的跨体系泛化能力。然而，Test3 的 lead time 缩短至 12.96 s，这一差异符合电池物理特性：与软包电池的渐进式失效不同，圆柱电池受内部电流中断装置（CID）动作影响，其热失控过程呈现毫秒级的“断崖式”电压归零特征。这与软包电池的失效机理存在本质差异：软包电池在微短路初期会经历产气鼓包过程，电极接触逐步恶化，因此电压呈现渐进式下降，给预警算法留出了较长的“观察期”；而 18650 圆柱电池的钢壳结构刚性，内部压力积聚到临界值时 CID 会瞬间断开电路，导致电压信号发生阶跃。这种物理机制上的“突变性”客观上压缩了所有基于电压特征算法的有效预警窗口，并非算法本身的迁移能力不足，而是受限于硬件保护机制的动作特性。

4.2 不同算法性能对比分析

为进一步验证所提架构及策略的先进性，本研究在 Test4 至 Test5 的迁移场景下，将 MS-TCN 与 Transformer、CNN 及标准 LSTM 进行了横向对比，并设置了去除小波增强（Exp1-nowav）与替换自适应阈值为固定阈值（Exp2-fixed）两组消融实验。为了保证对比的公平性，所有实验均以“零误报”（precision=1.0）为约束条件。在此前提下，固定阈值法（Exp2-fixed）被迫将安全边界放宽至

$k=6$ 以抑制环境噪声引发的误报，而本研究所提自适应方法及其他对比组均维持在更灵敏的 $k=3$ 水平。结果如表 2 及图 5 所示。图 5 直观量化了各模型在 $F1$ 分数（深蓝柱）、召回率（浅蓝柱）及提前预警时间（红色折线）上的多维性能差异。从图中可以清晰看到，本方法在所有指标上均在顶端——不仅 $F1$ 分数与召回率的柱状图高度为全组最高，且代表预警时间的红色折线维持在 30 s 附近的高位。

表 2 对比实验结果

Table 2 Comparative experimental results

实验组	Recall	F1-score	Lead time/s
Exp1-nowav	0.7975	0.8871	29.63
Exp2-fixed	0.9065	0.9510	21.74
Transformer	0.8044	0.8916	29.95
CNN	0.7970	0.8869	29.63
LSTM	0.8019	0.8900	29.52




图 5 不同模型及消融实验的综合性能对比

Fig. 5 Performance comparison of different models and ablation studies

对比结果显示，所有消融变体的 $F1$ 分数均出现 7% 以上的衰退，充分证实了完整模型设计的必要性。具体而言，去除小波增强后，recall 从 0.9335 显著跌至 0.7975，这意味着在没有小波“显微镜”作用下，微短路引发的毫伏级电压跌落被几十伏的背景电压完全“淹没”，模型无法区分这是故障信号还是正常的传感器抖动。将 MS-TCN 替换为 LSTM 时， $F1$ 降至 0.8900，这是因为 LSTM 的“记忆”随序列长度增加而衰退，面对长达数千时间步的电压数据，它难以关联起故障初期的微弱征兆与之后的温度爬升，丢失了“时序演化”这一关键判定维度。标准 CNN 则因感受野受限无法并

行提取多尺度特征，性能同样受损。这突显了 MS-TCN 利用空洞卷积获取指数级感受野在捕捉多尺度特征方面的架构优势。此外，固定阈值法虽能保持一定召回率，但 lead time 大幅缩短 7.89 s，原因是静态边界无法适应残差的动态分布，导致在早期微弱信号阶段发生漏报。尽管 Transformer 在 lead time 上略有优势，但其 $F1$ 仅为 0.8916，且二次方计算复杂度较高，在小样本迁移场景下易出现过拟合，相比之下，MS-TCN 在计算效率、泛化性与检测精度之间取得了更佳平衡，更适合 BMS 边缘计算环境^[22]。

4.3 阈值系数对预警性能的影响分析

EWMA 控制限参数 k 直接决定了检测策略的灵敏度与保守性。为探究其对预警性能的影响，本研究在 Test5 数据集上对不同 k 值进行了参数敏感性分析。

表 3 EWMA 参数敏感性分析结果

Table 3 Results of EWMA parameter sensitivity analysis

EWMA- k	Recall	F1-score	Lead time/s
3.0	0.9335	0.9656	29.63
4.0	0.7916	0.8837	29.63
5.0	0.0013	0.0027	29.52
6.0	0.0002	0.0004	25.77
8.0	0.0000	0.0001	25.77

实验结果显示，随着 k 值增大，检测策略趋于保守。虽然 precision 始终保持为 1.0（零误报），但 recall 与 $F1$ -score 呈断崖式下降。当阈值系数 k 增大至 6.0 时，recall 骤降至接近 0。这导致 $F1$ -score 随之崩塌。这一现象深刻揭示了固定阈值（或过高的自适应阈值）的缺陷：它为了极端的抗噪性能（不误报），完全牺牲了对微弱故障信号的捕捉能力（高漏报），从而失去了作为早期预警系统的实际价值^[23]。而本研究选取的 $k=3$ 在 $F1$ -score 上达到了最佳平衡，兼顾了零误报与高召回率。这证明了该参数设置在复杂工况下平衡误报率与漏报率的合理性与必要性。值得探讨的是，在实际的 BMS 工程部署中，为了进一步提升鲁棒性，可以设计动态的 k 值策略：在电池老化后期或低温工况等噪声较大的场景下，适当增大 k 值以抑制误报；而在快充或静置等对安全性要求极高的场景下，减小 k 值以保持系统的高灵敏度。这种“工况自适应”

的参数调节机制将是本方法工程化的重要方向。

5 结 论

本研究针对锂离子电池热失控早期微短路信号特征微弱及动态工况下误报率高的问题,提出了一种基于小波特征增强与 MS-TCN 的预警方法,并基于 JRC 数据集进行了实验验证。研究表明,利用离散小波变换提取电压高频细节并耦合温度趋势,能够在一定程度上增强微短路引起的毫伏级电压跌落特征,相比于直接使用原始电压数据,该策略有助于提升模型在强噪声背景下的特征捕捉能力。结合 MS-TCN 模型的空洞卷积结构,方法在计算量可控的前提下扩大了感受野,实现了对电压瞬态变化与温度长期趋势的同步关注;在同构软包电池测试中,该方法取得了 0.9784 的 $F1$ 分数,平均提前预警时间约为 29 s,并在跨电池类型的迁移测试中表现出了较好的泛化潜力。此外,所提出的 EWMA 自适应阈值策略通过根据预测残差的统计特性动态调整报警边界,在保证一定灵敏度的同时有效降低了因工况波动导致的误报现象,为电池安全监控提供了一种具备参考价值的决策方案。

受限于实验数据与现有条件,本研究仍存在一定局限性,特别是在圆柱电池等突变特征明显的场景下,仅依赖电压和温度信号的预警窗口相对有限。未来的工作将重点围绕以下方面展开:一是拓展多物理场数据源,拟尝试引入气压或应力等其他维度信号,以期在硬件机制限制下进一步提升预警的及时性;二是优化模型的工程适用性,研究模型轻量化技术,以适应计算资源受限的 BMS 嵌入式环境;三是提升全生命周期的适应能力,考虑到电池老化会引起特性漂移,后续计划引入迁移学习或在线更新机制,进一步验证并提升算法在电池全生命周期内的鲁棒性。四是拓展故障触发机制的验证范畴,针对当前实验数据主要来源于感应加热的局限,计划在具备安全防护条件的实验环境下,补充针刺、过充等破坏性实验数据,以全面评估算法在不同内短路诱因下的泛化性能。

参 考 文 献

- [1] 郭翠静, 褚永金, 刘庆. 锂离子电池表面形变影响因素分析及在热失控预警中的应用[J]. 储能科学与技术, 2025, 14(10): 3990-3995.
GUO C J, CHU Y J, LIU Q. Analysis of factors affecting surface deformation of lithium-ion battery and its application in thermal runaway early warning[J]. Energy Storage Science and Technology, 2025, 14(10): 3990-3995.
- [2] ZHANG X, CHEN S, ZHU J Z, et al. A critical review of thermal runaway prediction and early-warning methods for lithium-ion batteries[J]. Energy Material Advances, 2023, 4: 8. DOI:10.34133/energymatadv.0008.
- [3] 李昌豪, 曹志成, 汪书苹, 等. 基于时序模式注意力机制和孤立森林的电池过充热失控预警方法研究[J]. 储能科学与技术, 2025, 14(10): 3742-3754.
LI C H, CAO Z C, WANG S P, et al. Warning method for battery-overcharge thermal runaway based on a temporal pattern attention mechanism and an isolated forest algorithm[J]. Energy Storage Science and Technology, 2025, 14(10): 3742-3754.
- [4] WANG Y B, ZHANG C P, HU J, et al. Research on internal short circuit detection method for lithium-ion batteries based on battery expansion characteristics[J]. Journal of Power Sources, 2023, 587: 233673. DOI:10.1016/j.jpowsour.2023.233673.
- [5] REN S, SUN J. Multi-fault diagnosis strategy based on a non-redundant interleaved measurement circuit and improved fuzzy entropy for the battery system[J]. Energy, 2024, 292: 130603. DOI:10.1016/j.energy.2024.130603.
- [6] WANG S H, WANG Z P, CHENG X M, et al. A double-layer fault diagnosis strategy for electric vehicle batteries based on Gaussian mixture model[J]. Energy, 2023, 281: 128318. DOI:10.1016/j.energy.2023.128318.
- [7] CHANG C, WANG Q Y, JIANG J C, et al. Voltage fault diagnosis of a power battery based on wavelet time-frequency diagram[J]. Energy, 2023, 278: 127920. DOI:10.1016/j.energy.2023.127920.
- [8] ZHAO K, LIU Y, ZHOU Y, et al. Digital twin-supported battery state estimation based on TCN-LSTM neural networks and transfer learning[J]. CSEE Journal of Power and Energy Systems, 2025, 11(2): 567-579. DOI: 10.17775/CSEEJPES.2024.00900.
- [9] LI M R, DONG C Y, WANG R, et al. Synthetic thermal convolutional-memory network for the lithium-ion battery behaviour diagnosis against noise interruptions[J]. IET Energy Systems Integration, 2023, 5(1): 29-39. DOI:10.1049/esi2.12080.
- [10] GHAZALI A K, AZIZ N A A, HASSAN M K. Advanced algorithms in battery management systems for electric vehicles: A comprehensive review[J]. Symmetry, 2025, 17(3): 321. DOI: 10.3390/sym17030321.
- [11] 张朝龙, 陈阳, 刘梦玲, 等. 一种基于 ICA-T 特征和 CNN-LA-BiLSTM 的锂离子电池健康状态估计方法[J]. 储能科学与技术, 2025, 14(3): 1258-1269.
ZHANG C L, CHEN Y, LIU M L, et al. A state of health estimation method for lithium-ion batteries using ICA-T features and CNN-LA-BiLSTM[J]. Energy Storage Science and Technology, 2025, 14(3): 1258-1269.
- [12] 黄强, 陈一童, 王备, 等. 融合多尺度 TCN 与动态注意力的电池容量预测[J]. 电池, 2025, 55(5): 1034-1041. DOI: 10.19535/j. 1001-1579.2025.05.023.
HUANG Q, CHEN Y T, WANG B, et al. Prediction of battery

- capacity based on multi-scale TCN and dynamic attention[J]. *Battery Bimonthly*, 2025, 55(5): 1034-1041. DOI:10.19535/j.1001-1579.2025.05.023.
- [13] DONG Z K, GU S Y, ZHOU S Q, et al. Periodic segmentation transformer-based internal short circuit detection method for battery packs[J]. *IEEE Transactions on Transportation Electrification*, 2025, 11(1): 3655-3666. DOI: 10.1109/TTE.2024.3444453.
- [14] ANSARI S, AYOB A, HOSSAIN LIPU M S, et al. Data-driven remaining useful life prediction for lithium-ion batteries using multi-charging profile framework: A recurrent neural network approach[J]. *Sustainability*, 2021, 13(23): 13333. DOI: 10.3390/su132313333.
- [15] LI S P, ZHANG H, MISUL D A, et al. Battery temperature anomaly early warning for electric vehicles under real driving conditions using a temporal convolutional network[J]. *eTransportation*, 2025, 25: 100445. DOI: 10.1016/j.etrans.2025.100445.
- [16] CHENG Y M, GAO D X, ZHAO F M, et al. A thermal runaway early warning method for electric vehicles based on hybrid neural network model[J]. *Journal of Electrical Engineering & Technology*, 2024, 19(6): 3735-3748. DOI:10.1007/s42835-024-01825-8.
- [17] 胡杰, 王浩杰, 魏敏, 等. 基于TCN-LSTM模型的实车电池健康状态评估方法[J]. *汽车工程*, 2025, 47(6): 1060-1071.
- HU J, WANG H J, WEI M, et al. A TCN-LSTM model-based approach for real vehicle battery health state evaluation[J]. *Automotive Engineering*, 2025, 47(6): 1060-1071.
- [18] 周航, 程泽, 弓清瑞, 等. 基于TCN编码的锂离子电池SOH估计方法[J]. *湖南大学学报(自然科学版)*, 2023, 50(4): 185-192. DOI: 10.16339/j.cnki.hdxzbzkb.2023228.
- ZHOU H, CHENG Z, GONG Q R, et al. SOH estimation method of lithium-ion battery based on TCN encoding[J]. *Journal of Hunan University (Natural Sciences)*, 2023, 50(4): 185-192. DOI: 10.16339/j.cnki.hdxzbzkb.2023228.
- [19] 叶震, 李琨, 李梦男, 等. 改进EWMA和多通道混合模型的锂电池容量预测[J]. *机械科学与技术*, 2025, 44(3): 513-520. DOI:10.13433/j.cnki.1003-8728.20230185.
- YE Z, LI K, LI M N, et al. Lithium battery capacity prediction using improved exponentially weighted moving average and multi-channel hybrid model[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2025, 44(3): 513-520. DOI: 10.13433/j.cnki.1003-8728.20230185.
- [20] ZHANG X Y, YANG W H, YAN L S, et al. Adaptive internal short-circuit fault detection for lithium-ion batteries of electric vehicles [J]. *Journal of Energy Storage*, 2024, 84: 110874. DOI:10.1016/j.est.2024.110874.
- [21] KRISTON A, KERSYS A, ANTONELLI A, et al. Initiation of thermal runaway in Lithium-ion cells by inductive heating[J]. *Journal of Power Sources*, 2020, 454: 227914. DOI: 10.1016/j.jpowsour.2020.227914.
- [22] ZHAO J Y, FENG X N, WANG J B, et al. Battery fault diagnosis and failure prognosis for electric vehicles using spatio-temporal transformer networks[J]. *Applied Energy*, 2023, 352: 121949. DOI: 10.1016/j.apenergy.2023.121949.
- [23] SHEN D X, LYU C, YANG D Z, 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. DOI:10.1016/j.energy.2024.132467.