

PRIME-TR: 一种面向储能系统热失控预警的风险映射与持续触发决策框架

李福^{1,2}, 吕伟¹, 孙玉玺³

(1. 武汉理工大学 安全科学与应急管理学院, 武汉 430070; 2. 中天亿信大数据(武汉)有限公司, 武汉 430073; 3. 中南财经政法大学 信息工程学院, 武汉 430073)

摘要: 锂离子电池热失控演化快、危害强, 是储能系统安全运行中的关键风险。现有固定阈值预警方法通常需要等状态明显偏离正常范围后才触发告警, 难以同时兼顾预警提前量与误报控制; 不同工况与电芯差异还会引起异常评分尺度漂移, 削弱固定阈值判定的一致性。针对上述问题, 本文提出一种面向储能系统热失控预警的风险映射与持续触发决策框架(PRIME-TR)。该框架不增加额外传感器, 仅依赖电池管理系统获取的多变量时序数据, 通过“异常感知—风险映射—持续触发”三阶段结构, 将底层异常评分转换为具有分位语义的风险评分, 并在决策层引入持续触发约束, 以输出更稳定的预警结果。在动态压力测试、联邦城市行驶工况及跨电芯验证场景下, PRIME-TR 在固定阈值条件下均未出现误报。基于 NLR 电池故障数据库热诱导失效实验的统一评价结果表明, 相对于电芯内部不可逆结构持续扩展的参考时刻, PRIME-TR 可实现 0.366 7 min(约 22 s)的提前预警, 优于温度阈值、电压阈值、EWMA、Isolation Forest、PCA-T² 和 COPOD 等方法。进一步的虚拟机柜并行实验表明, 在指数 $N=500$ 的系统规模下, 该框架仍能保持可控的系统级误报水平, 并可通过决策层时间门控抑制同步瞬态扰动带来的误报放大。结果表明, PRIME-TR 在不改变底层检测器的前提下提升了风险判定一致性与预警输出稳定性, 可为储能系统热失控在线预警提供可部署的决策层方案。

关键词: 热失控; 储能系统; 风险映射; 持续触发; 早期预警; 多变量时序

中图分类号: X 924.2 文献标志码: A

PRIME-TR: a risk-mapping and persistent-triggering decision framework for thermal runaway warning in energy storage systems

LI Fu^{1,2}, LYU Wei¹, SUN Yuxi³

(1. School of Safety Science and Emergency Management, Wuhan University of Technology, Wuhan 430070, China; 2. ZTYS Big Data (Wuhan) Co., Ltd., Wuhan 430073, China; 3. School of Information Engineering, Zhongnan University of Economics and Law, Wuhan 430073, China)

收稿日期: 2026-04-15

基金项目: 中国工程院科技战略咨询项目(2025-XZ-135)

第一作者: 李福(1981—), 男, 博士。研究方向: 风险智能预测与控制、智慧应急、储能安全。E-mail: 492566@qq.com

通信作者: 吕伟(1989—), 男, 教授。研究方向: 城市公共安全风险分析、应急资源与人员安全保障、公共交通风险评估。E-mail: weil@whut.edu.cn

引文格式: 李福, 吕伟, 孙玉玺. PRIME-TR: 一种面向储能系统热失控预警的风险映射与持续触发决策框架[J]. 上海理工大学学报, 2026, 48(3): 253-264.

Citation: LI Fu, LYU Wei, SUN Yuxi. PRIME-TR: a risk-mapping and persistent-triggering decision framework for thermal runaway warning in energy storage systems[J]. Journal of University of Shanghai for Science and Technology, 2026, 48(3): 253-264.

Abstract: Thermal runaway of lithium-ion batteries evolves rapidly and causes severe hazards, making it a critical safety risk for the safe operation of energy storage systems. Conventional fixed-threshold warning methods usually trigger alarms only after the system state has significantly deviated from normal conditions, making it difficult to balance warning lead time and false alarm control. Moreover, variations in operating conditions and cell-to-cell differences may lead to scale drift in anomaly scores, thereby weakening the consistency of fixed-threshold decisions. To address these problems, a risk-mapping and persistent-triggering decision framework for thermal runaway warning in energy storage systems, namely persistent triggering, risk mapping, input representation, multi-stage evaluation, and engineering deployment for thermal runaway (PRIME-TR) was proposed. Without adding extra sensors, the framework only relied on multivariate time-series data available from the battery management system. Through a three-stage structure of "anomaly perception-risk mapping-persistent triggering", raw anomaly scores were transformed into risk scores with quantile semantics, and persistent-triggering constraints were introduced at the decision layer to generate more stable warning outputs. In dynamic stress test, federal urban driving schedule, and cross-cell validation scenarios, PRIME-TR produced no false alarms under fixed-threshold conditions. Unified evaluation results based on thermally induced failure experiments from the NLR battery failure databank show that PRIME-TR achieves a warning lead time of 0.366 7 min, approximately 22 s, relative to the reference time of sustained irreversible structural propagation inside the cell, outperforming temperature threshold, voltage threshold, EWMA, Isolation Forest, PCA-T², and COPOD. Further virtual cabinet parallel experiments show that, at a system scale of $N=500$, the proposed framework can still maintain controllable system-level false alarms and suppress false alarm amplification caused by synchronous transient disturbances through decision-layer temporal gating. The results indicate that PRIME-TR improves the consistency of risk decisions and the stability of warning outputs without changing the underlying detector, providing a deployable decision-layer solution for online thermal runaway warning in energy storage systems.

Keywords: *thermal runaway; energy storage systems; risk mapping; persistent triggering; early warning; multivariate time series*

锂离子电池具有较高的能量密度和良好的循环性能,已成为大规模储能系统的核心储能单元。但在材料老化、制造缺陷、高倍率充放电以及外部热扰动等因素的作用下,电芯有可能发生热失控(thermal runaway, TR)现象。Feng等^[1]指出,TR本质上是由内部放热反应触发并持续自加速的非线性演化过程。Spotnitz等^[2]的研究表明,电芯在热激励下会迅速进入不可逆失效阶段。Finegan等^[3]基于原位高速X射线成像发现,TR内部结构坍塌可在数十秒内完成。Larsson等^[4]进一步指出,TR过程中会释放有毒氟化气体,对周边环境和人员安全构成威胁。随着储能系统规模不断扩大,TR的早期识别与及时处置已成为安全运行中的关键问题。Ren等^[5]对TR预测中的主要

难点进行了系统梳理。Zhang等^[6]的最新综述表明,尽管电化学-热耦合建模研究持续推进,但面向复杂运行场景的可部署预测方案仍需解决参数漂移和结果不确定性等问题。

在工程应用中,电池安全监测主要依赖电池管理系统(battery management system, BMS)实时采集的电压、电流和温度信号。Liu等^[7]对BMS关键技术的综述表明,在线监测能力受限于传感器可获取变量。现有预警方法多采用温度绝对阈值、温升速率或电压异常等规则进行判定^[8-9]。这类方法简单易实现、部署成本低,但通常要在系统状态已明显偏离正常范围后才触发告警,预留的处置时间有限;同时,其判定结果还容易受到工况波动和电芯一致性差异的影响,稳定性不足^[10]。

近年来,机器学习与多变量统计分析方法逐步被引入电池异常检测与失效预测研究。Kouhestani等^[11]提出以数据驱动为核心的电池失效检测与前瞻性预测方法,验证了仅依托在线运行数据识别潜在失效征兆的可行性。Susto等^[12]指出,多变量时序建模能够提升复杂工业系统的异常识别能力。Liu等^[13]提出的 Isolation Forest 方法通过随机划分实现无监督异常检测,为无需标签数据的可扩展风险识别提供了基础算法框架。近期研究进一步探索结合可解释深度学习的电池性能退化与寿命预测方法^[14],也表明数据驱动模型在复杂电化学系统状态建模方面具有较强表达能力。与单变量阈值方法相比,多变量数据驱动策略更有利于刻画系统状态的渐进偏移及耦合演化特征。

然而,从工程部署角度看,现有研究仍有两个薄弱环节。其一,许多工作重点放在异常检测或预测模型本身,而对“异常评分如何转化为可执行、可长期运行的预警决策”讨论不足。在线运行中,异常评分往往存在短时波动,若直接采用单时刻越阈触发,容易引发报警抖动。其二,在跨工况和跨电芯场景下,异常评分分布可能发生漂移,固定阈值难以保持一致的风险含义,从而影响长期部署的稳定性。对于储能系统而言,误报控制和决策一致性并不只是附属指标,而是决定方法能否落地的关键条件^[15]。

针对上述问题,本文提出一种面向储能系统 TR 预警的风险映射与持续触发决策框架(persistent triggering, risk mapping, input representation, multi-stage evaluation, engineering deployment for thermal runaway, PRIME-TR)。该框架以多变量异常感知结果为输入,先通过风险映射将原始异常评分统一到具有分位语义的风险空间,再在决策层引入持续触发约束,以输出稳定的报警结果。其目标不是设计新的底层异常检测器,而是在既有检测结果之上建立一套更适合工程部署的决策层机制。

为验证 PRIME-TR 的有效性,本文基于 CALCE A123 LiFePO₄ 电池数据集^[16]完成正常运行建模、固定阈值验证以及跨工况、跨电芯泛化实验,结合 NLR 电池故障数据库(NLR battery failure databank, Nbfd)^[17]中的热诱导失效数据评估事件级提前预警能力。在此基础上,进一步构建虚拟机柜并行场景,分析规模扩展条件下的误报放大现象及其抑制机制。

1 问题定义、工程约束与评价指标

本文面向储能系统既有 BMS 变量条件下的 TR 早期预警,关注在不增加硬件改造成本的前提下实现可部署、可复用且误报可控的预警决策。

1.1 TR 早期预警方法的技术生态位分析

现有锂离子电池 TR 早期预警方法已形成多条技术路线^[18]。对于储能系统场景,预警方法不仅需要具备对复杂异常演化过程的表达能力,还需满足在线计算可承受、硬件改造可接受以及阈值策略可长期维持等工程要求。本文以“系统部署复杂度”和“异常表达能力”为两个维度,构建技术生态位分析框架,如图 1 所示。结合已有研究,相关方法大致可归纳为 5 类:




图 1 TR 早期预警方法的技术生态位分布
Fig.1 Technical niche distribution of TR early warning methods

- a. 阈值与统计规则方法: 依据温度、电压或温升速率等规则进行判定,部署简单,但异常表达能力有限^[18]。
 - b. 机制特征驱动方法: 依赖具有物理指向性的特征开展判定,可解释性较强,但实现复杂度较高^[19]。
 - c. 多参数融合与数据驱动方法: 可增强对复杂异常的表达能力,但对数据质量和模型稳定性要求更高^[20]。
 - d. 硬件增强型多模态方法: 通过气体等附加信号增强感知能力,需承担额外硬件改造成本^[21]。
 - e. 实时检测与严重度预测框架: 兼具异常识别与风险评估能力,计算和实现负担相对较高^[22]。
- 总体来看,不同技术路线在异常表达能力和部署复杂度之间存在明确权衡^[23]。规则类方法易部署但能力有限,多变量数据驱动方法表达能力更强但稳定性要求更高,多模态增强方法灵敏度

更高但硬件代价较大。PRIME-TR 的定位是在既有 BMS 变量条件下,通过多变量时序建模、风险映射和持续触发机制,提高预警决策的一致性与可部署性^[24]。

1.2 工程可获取性约束与变量体系构建

PRIME-TR 的输入限定在 BMS 可直接获取的数据范围内,不引入气体、压力、声学或侵入式测试信号^[25]。输入变量包括单体电压 $V(t)$ 、电流 $I(t)$ 、电池温度 $T(t)$ 及荷电状态 (state of charge, SOC) (t) 等基础监测量,在此基础上进一步构造电流变化率 dI/dt 、物理模型残差 $r(t)$ 及滑动统计特征等派生变量。基础监测量反映运行状态,派生变量用于补充动态响应、模型失配与局部突变信息。

1.3 数据集分层设计与验证框架

为同时评估误报控制能力、跨分布稳定性和事件级提前预警能力,本文采用两类互补数据构建分层验证框架。

a. 正常运行与可逆动态阶段数据: 用于异常感知模型训练、阈值标定、正常运行稳定性验证以及跨工况、跨电芯泛化评估;

b. TR 事件数据: 用于界定事件级参考时刻并评估提前预警能力,不参与模型训练或参数调整。

这种分层设计将正常运行阶段的长期稳定性评估与 TR 事件场景下的提前预警分析纳入同一框架,同时避免事件数据对正常阶段建模过程产生反向干扰^[26]。

1.4 多变量时序表示方法

设时刻 t 的 BMS 多变量运行状态向量表示为

$$\mathbf{x}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_d(t) \end{bmatrix} \in \mathbb{R}^d \quad (1)$$

式中: d 为 BMS 可观测变量的维度; $x_d(t)$ 为第 d 个运行变量在时刻 t 的观测值; $\mathbf{x}(t)$ 为列向量形式的系统运行状态。

为刻画短时间尺度内的动态演化特征,引入长度为 L 的滑动时间窗口,构造多变量时序片段矩阵:

$$\mathbf{X}_t = [x(t-L+1), x(t-L+2), \dots, x(t)] \in \mathbb{R}^{d \times L} \quad (2)$$

式中: L 为时间窗口长度; 每一列为一个时间步的状态向量; $\mathbf{X}_t$ 为时刻 t 的多变量时序片段。该表达式为后续异常感知模型提供统一输入形式。

1.5 TR 起始时刻的工程评估定义

为实现可复现的性能评估,本文需要对“TR 起始时刻”给出统一工程定义。这里不追求一般场景下电化学反应微观起点的精确刻画,而是从储能系统安全工程角度出发,采用基于 BMS 可观测量的判据化定义作为统一评估基准。

设 TR 起始时刻为 t_{TR} , 定义为满足以下任一条件的最早时间点:

$$t_{\text{TR}} = \inf \left\{ t \mid (T(t) \geq T_{\text{th}}) \left(\frac{dT(t)}{dt} \geq \gamma \Delta t \geq \tau_{\text{th}} \right) \right\} \quad (3)$$

式中: $T(t)$ 为电池温度; T_{th} 为预设安全温度阈值; $\frac{dT(t)}{dt}$ 为温升速率; γ 为温升速率阈值; τ 为温升速率持续时间要求; Δt 为温升速率超过阈值的连续时间长度。该定义对应两类工程可观测触发条件: **a.** 绝对温度越界; **b.** 温升速率持续异常。

上述定义用于统一提前预警时间 t_L 的统计口径和方法间比较标准,不等同于电芯内部微观失效起点的严格物理定义。在具备高帧率成像或更细粒度事件标注的条件下,可进一步引入更精细的事件级参考时刻。

1.6 早期预警问题形式化与评价指标

在多变量时序预警框架中,底层模型首先输出异常评分 $s(t)$, 用于表征当前状态相对于正常模式的偏离程度; 经风险映射后得到风险评分 $R(t)$, 作为决策层输入。

$$t_{\text{alarm}} = \inf \{ t \mid R(t) > \theta \} \quad (4)$$

结合第 1.5 节定义的 TR 起始时刻 t_{TR} 和预警时间 t_{alarm} , 若 $t_{\text{alarm}} < t_{\text{TR}}$, 则认为模型实现了一次有效的事前预警。

1.6.1 提前预警时间

为量化预警策略提供的工程干预窗口,提前预警时间为

$$t_L = t_{\text{TR}} - t_{\text{alarm}} \quad (5)$$

式中: $t_L > 0$ 表示预警发生在 TR 之前; $t_L \leq 0$ 表示预警滞后或未在失效转折前给出有效提示。

1.6.2 代价敏感评价模型

考虑误报与漏报在工程上的后果不同,引入综合运行代价:

$$C = \alpha F_P + \beta F_N \quad (6)$$

式中: F_P 和 F_N 分别为误报次数与漏报次数; α 和 β 为对应的代价权重。通常取 $\beta > \alpha$, 以反映漏报

的更高安全代价。

1.6.3 泛化性能定义

设训练阶段数据分布为 P_{train} , 测试阶段数据分布为 P_{test} , 若在 $P_{\text{train}} \neq P_{\text{test}}$ 的条件下, 模型在不重新标定阈值和决策参数的前提下仍能保持较低误报率、稳定的风险阈值语义和可接受的提前预警能力, 则认为其具备工程意义上的泛化能力。

2 PRIME-TR: 风险映射与持续触发决策框架

2.1 总体架构与三阶段映射结构

针对储能系统中 TR 风险演化复杂、误报代价高且运行工况多变的特点, PRIME-TR 采用三阶段映射结构:

$$t_A = D\{R[A(X_t)]\} \quad (7)$$

式中: A 为异常感知映射, 输出异常评分; t_A 为异常感知时间; R 为风险评分映射, 将异常响应统一转换为分位语义尺度; D 为持续触发决策映射, 在时间维度施加一致性约束, 输出最终报警信号。

该结构将“异常数值—风险语义—工程触发”分为 3 个层次处理, 使底层检测器与上层预警决策解耦。图 2 给出了框架的在线执行与离线评估路径: 在线部分依次完成异常感知、风险映射与持续触发判断; 离线部分仅用于计算 t_L 与代价指标, 不参与实时决策。

2.2 第一阶段: 多变量异常感知映射

设时间 t 的多变量状态窗口为 X_t , 第一阶段通过异常检测映射:

$$s(t) = A(X_t) \quad (8)$$

式中, $s(t)$ 为输出异常评分, 用于刻画当前运行状态相对于正常模式的偏离程度。

本阶段不限定具体检测算法, 只要求模型能够在正常运行数据条件下稳定输出可比较的异常评分序列。该设计保证了 PRIME-TR 与不同异常检测器之间的结构兼容性。

2.3 第二阶段: 风险映射机制

在不同工况、电芯个体或输入数据分布变化条件下, 原始异常评分 $s(t)$ 的数值尺度可能发生漂移。若直接对 $s(t)$ 设定固定阈值, 则相同阈值在不同场景中的风险含义可能并不一致。

为此, 本文基于正常运行阶段异常评分构建经验累积分布函数 (empirical cumulative distribution




图 2 PRIME-TR 总体架构

Fig.2 Overall architecture of PRIME-TR

function, ECDF)。设 $\hat{F}_{\text{train}}(\cdot)$ 表示训练阶段异常评分的经验分布, 则风险评分定义为

$$R(t) = \hat{F}_{\text{train}}(s(t)), \quad R(t) \in [0,1] \quad (9)$$

式中, $R(t) \in [0,1]$ 表示当前异常响应在历史正常分布中的分位水平。该映射为单调非参数变换, 不依赖特定分布假设, 既保留异常评分的相对排序关系, 又将其统一到具有概率语义的风险空间。

经风险映射后, 固定阈值不再对应原始评分的绝对数值, 而对应“超过正常分布中某一分位水平”的统一语义。这为跨工况和跨电芯条件下维持一致的决策边界提供了基础。

2.4 第三阶段: 持续触发决策机制

TR 风险通常呈持续积累特征, 而在线风险评分 $R(t)$ 可能因瞬态扰动出现短时越阈。若直接采用单时刻判定, 容易产生报警抖动或瞬时误触发。为此, 本文在风险评分层引入持续触发机制: 只有当 $R(t)$ 连续超过阈值 θ 且持续长度达到 τ_{cell} 时, 才输出报警。

预警触发时刻定义为

$$t_{\text{alarm}} = \inf\{t | R(t - \tau_{\text{cell}} + 1), \dots, R(t) > \theta\} \quad (10)$$

式中: $\theta \in (0,1)$ 为风险阈值; τ_{cell} 为单体持续长度。

在近似独立假设下, 若单点误触发概率为 p , 则持续触发机制下误报概率近似为

$$P(\text{false alarm}) \approx p^{\tau_{\text{cell}}} \quad (11)$$

因此, 当 $\tau_{\text{cell}} > 1$ 时, 误报概率随持续长度增加

而快速下降。该表达主要用于说明持续触发对误报的抑制趋势，并不用于严格刻画实际相关时序条件下的精确概率。

为增强实际部署可行性， θ 可取训练阶段异常评分的高分位数(如 $q=0.995$)，并根据系统动态特征适当微调；而 τ_{cell} 则可依据采样频率和典型异常演化时间窗口进行选择，高动态工况取较短值以快速响应，低动态工况取较长值以抑制瞬态误触发，通常范围为10~60 s。本实验采样频率为1 Hz，因此 $\tau_{\text{cell}}=60$ 时，对应约60 s的持续越阈判定窗口。

3 实验设计与实现

3.1 数据集与验证框架

3.1.1 正常运行数据

正常运行阶段数据来自 CALCE A123 LiFePO₄ 电池数据集^[16]，包含动态压力测试(dynamic stress test, DST)、联邦城市行驶工况(federal urban driving schedule, FUDS)和 US06 高速公路驾驶工况等典型动态工况，采集变量包括电压、电流、温度和荷电状态。实验设置如下：A1-007 DST 数据用于模型训练与阈值标定；A1-008 DST 数据用于跨电芯迁移验证；FUDS 数据用于跨工况泛化验证；所有测试阶段均保持阈值和持续触发参数不变。

该设置对应“历史正常数据建模-在线顺序推理”的工程应用模式。

3.1.2 TR 事件数据

为评估事件级提前预警能力，本文选取 NBFD 中的热诱导失效实验数据。实验对象为满充状态下的 18650 电芯，外部热源诱导失效，并同步提供高帧率高速 X 射线成像数据。该部分数据仅用于界定事件级参考时刻和计算 t_L ，不参与模型训练或参数标定。

3.2 物理基线与特征构建

为增强对动态运行状态的刻画能力，本文在多变量时序输入基础上引入基于等效电路模型(equivalent circuit model, ECM)的电压预测残差 $r(t)$ 作为辅助特征。该残差表征物理模型未能解释的动态偏差，可补充数据驱动特征在机理约束和突变敏感性方面的不足。

为构建该残差特征，首先需确定 ECM 中开路电压(open circuit voltage, OCV)-SOC 关系的参考基线。本文基于 25 °C 条件下的多电芯数据建立 OCV-SOC 查表关系，并采用中位数融合以降低个

体差异和异常测量点的影响。选取 25 °C 作为参考条件，是因为其接近锂离子电池常规标定和运行分析中的标准工况，能够减少温度差异对 OCV-SOC 关系的干扰，从而为残差计算提供更稳定基准。图 3 展示了不同电芯 OCV-SOC 曲线及其中位数融合结果。




图 3 不同电芯 OCV-SOC 曲线及其中位数融合结果

Fig.3 OCV-SOC curves of different cells and median fusion result

在此基础上，异常感知阶段采用“基础监测量、动态派生量和物理残差”的联合表示方式，具体输入变量见第 2.2 节。

3.3 对比方法与公平性设置

为评估 PRIME-TR 的结构贡献，本文选取阈值型方法、单变量异常检测方法和多变量异常检测方法作为对比基线，见表 1。所有方法均遵循以下统一设置：

- 仅使用正常运行数据进行训练；
- 测试阶段不重新调整参数或阈值；
- 滑动窗口长度和数据预处理流程一致；
- 统一采用持续触发机制输出预警时刻。

3.4 训练策略与实现环境

滑动时间窗口长度设为 $L=60$ 个时间步，在 1 Hz 采样频率下对应约 60 s 的历史观测窗口，以覆盖典型异常演化阶段并控制在线计算复杂度。异常评分阈值依据训练集统计分布按分位数原则确定；测试阶段保持阈值 θ 固定，持续触发参数 τ_{cell} 不变，以评估模型在分布变化条件下的泛化能力。所有实验基于 Python 3.12 实现，主要依赖 NumPy、SciPy、Scikit-learn、PyOD 和 PyBaMM^[27] 等开源库，并在统一计算环境下运行。

4 实验验证与结果分析

围绕 PRIME-TR 的工程化预警性能展开验

表 1 基于 BMS 数据的代表性 TR 早期预警方法结构特征对比

Tab.1 Comparison of structural characteristics of representative TR early warning methods based on BMS data

方法类别	方法名称	多变量建模	显式时序建模	风险尺度统一	持续触发机制	支持跨分布固定阈值
阈值型方法	温度阈值	×	×	×	√	×
阈值型方法	电压阈值	×	×	×	√	×
单变量异常检测	EWMA	×	√(递归统计)	×	√	×
单变量异常检测	Isolation Forest	×	×	×	√	×
多变量异常检测	PCA-T ²	√	×	×	√	×
多变量异常检测	COPOD	√	×	×	√	×
本文方法	PRIME-TR	√	√(窗口建模)	√	√	√

注: 所有方法均基于BMS可获取变量构建; “显式时序建模”指模型结构直接刻画时间依赖关系; 差分运算或滑动窗口统计不视为显式时序模型; 持续触发机制指在决策层施加时间一致性约束。

证, 依次考察残差特征有效性、正常运行阶段稳定性、跨工况与跨电芯泛化能力、持续触发决策机制、事件级提前预警能力以及系统级可部署性, 从而形成由特征构建到部署评估的完整证据链。

4.1 ECM 残差有效性与动态特征分析

4.1.1 ECM 电压残差构建结果

在异常建模之前, 首先构建电池运行的物理预测基线。基于 PyBaMM 平台, 本文在 CALCE A123 LiFePO₄ 电池 DST 工况下对 1-RC、2-RC 及扩展串联电阻模型进行参数辨识, 结果见表 2。不同模型结构在均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE)

上差异很小, 说明在该动态工况下, 引入额外 RC 支路并未显著改善预测精度。因此, 后续分析采用结构更简洁的 1-RC 模型作为物理基线。

图 4 给出了实测端电压与 ECM 预测电压的对比结果。总体上, ECM 能够较好刻画电压变化趋势, 但在电流快速变化阶段仍存在局部偏差。为量化这部分模型未解释的动态成分, 定义电压残差为

$$r(t) = V_{\text{meas}}(t) - V_{\text{ECM}}(t)$$

(12)

式中: $V_{\text{meas}}(t)$ 为实测端电压; $V_{\text{ECM}}(t)$ 为 ECM 预测电压。残差 $r(t)$ 表示物理模型与真实运行响应之间的失配程度, 可作为后续异常建模的辅助特征。

表 2 ECM 结构下的参数辨识结果 (CALCE DST 工况)

Tab.2 ECM parameter identification results (CALCE DST condition)

模型结构	SOC	标称容量 <i>Q</i> /Ah	<i>R</i> ₀ /Ω	<i>R</i> ₁ /Ω	<i>C</i> ₁ /F	<i>R</i> ₂ /Ω	<i>C</i> ₂ /F	<i>R</i> _{fixture} /Ω	RMSE/V	MAE/V
1-RC ECM	0.35	1.50	0.130 5	0.052 7	2 500	—	—	—	0.128 0	0.076 9
2-RC ECM	0.35	1.50	0.130 5	0.052 7	2 500	0.015 0	8 000	—	0.128 0	0.076 9
1-RC + <i>R</i> _{fixture}	0.35	1.50	0.130 5	0.052 7	2 500	—	—	-1.0×10^{-6}	0.128 0	0.076 9

注: “—”表示该模型结构中未包含对应参数; RMSE与MAE基于CALCE DST全时域数据统计; *R*_{fixture}表示测量链路串联等效电阻项。该参数辨识结果为 $-1.0 \times 10^{-6} \Omega$, 量级接近0, 系数值优化中的微小浮点扰动所致, 可视为0。

4.1.2 残差统计特征分析

全时域统计结果见表 3。残差均值为 0.025 7 V, 相对于整体波动尺度较小, 未呈现明显系统性偏移。

图 5 显示, 残差在平稳区段围绕零附近波动, 在高 dI/dt 区域局部放大, 并对 SOC 呈现轻微依赖。这表明残差并非纯随机噪声, 而包含一定的动态结构信息。因而, 将残差引入多变量时序表示有助于增强异常感知阶段对模型未解释动态响应的刻画能力。

4.2 正常运行阶段稳定性与固定阈值验证

本节验证风险映射和固定阈值机制在正常运行条件下的稳定性。仅使用正常运行数据完成异常感知模型训练和风险阈值标定后, 将固定阈值策略直接应用于同分布测试数据, 风险评分 $R(t)$ 与阈值的对比如图 6 所示。

从图 6 可见, 在整个测试区间内, 风险评分 $R(t)$ 未出现持续越阈现象, 系统未触发报警事件。对应误报统计结果见表 4。PRIME-TR 在自一致性




图 4 DST 工况下实测端电压与 ECM 预测电压

Fig.4 Measured terminal voltage and ECM predicted voltage under DST condition

表 3 ECM 电压预测残差统计特征(DST 全时域)

Tab.3 ECM voltage residual statistical characteristics (DST all-time domain condition)

指标	数值
样本数 n	24 469
残差均值/V	0.025 7
Std(r)	0.128 3
RMSE/V	0.130 9
MAE/V	0.074 4
95%分位绝对残差/V	0.283 0
min(r)/V	-0.296 0
max(r)/V	1.215 1

场景 (DST→DST)和跨电芯场景 (A1-007→A1-008) 下均保持报警事件率为 0/h。

这一结果说明，在正常运行条件下，PRIME-TR 能够在固定阈值策略下维持稳定输出，为后续跨工况、跨电芯及规模扩展场景中的统一阈值应用提供依据。

4.3 跨工况与跨电芯泛化能力验证

为评估 PRIME-TR 在分布变化条件下的稳定性，在风险阈值与固定阈值持续触发参数 τ 不变的条件下设计 3 类泛化实验。所有实验均保持训练阶段获得的阈值和决策参数不变，不进行重新标定或参数调整。图 7 给出了 3 类场景下风险评分与固定阈值的对比。




图 5 ECM 电压残差在不同动态条件下的统计特征

Fig.5 Statistical characteristics of ECM voltage residuals under dynamic conditions




图 6 正常运行阶段 $R(t)$ 与固定阈值的对比

Fig.6 Comparison of the $R(t)$ with the fixed threshold during normal operation

4.3.1 自一致性验证(DST → DST)

在同分布测试条件下，报警事件率为 0 次/h。如图 7(a) 所示， $R(t)$ 在整个测试区间内始终低于阈

表 4 正常运行阶段误报统计结果

Tab.4 False alarm statistics during normal operation

方法类别	方法名称	A1-007 DST(self) 报警事件率/(次·h ⁻¹)	A1-008 DST(cross) 报警事件率/(次·h ⁻¹)	最大事件率/(次·h ⁻¹)	是否发生报警
多变量异常检测	PCA-T ²	0	0.098	0.098	是
多变量异常检测	COPOD	0	0	0	否
本文方法	PRIME-TR	0	0	0	否




图 7 不同泛化场景下的 $R(t)$ 与 θ 的对比结果 ($L=60, K=60, H=60, q=0.995$)

Fig.7 Comparison results of the $R(t)$ in different generalization scenarios with the θ ($L=60, K=60, H=60, q=0.995$)

值 θ , 仅存在短时波动, 未形成持续越界。

4.3.2 跨工况泛化验证 (DST → FUDS)

FUDS 工况具有更高频率的电流波动和更复杂的动态响应。实验结果表明, 报警事件率仍为 0 次/h。图 7(b) 显示, 尽管评分波动幅度有所变化, 但整体分布未出现导致持续越阈的系统性抬升。

4.3.3 跨电芯泛化验证 (A1-007 → A1-008)

在存在电芯个体差异的条件下, 报警事件率同样保持为 0 次/h。图 7(c) 表明, 风险评分 $R(t)$ 的整体分布未发生明显偏移, 也未观察到持续性越界。

综合来看, PRIME-TR 在固定阈值条件下能够在同分布、跨工况和跨电芯场景中保持稳定判定结果, 说明其决策层输出具有较好的跨场景一致性。

4.4 持续触发决策机制与成本敏感性分析

第三阶段持续触发决策将风险评分序列 $R(t)$ 转换为稳定预警信号, 其核心作用是抑制瞬态越阈对最终告警的干扰。为考察该机制在不同安全偏好下的运行表现, 本文基于第 1.6 节定义的代

价敏感评价模型, 对不同方法的综合运行代价进行比较。

图 8 展示了不同方法在持续触发机制下的成本敏感性变化趋势。对于未产生漏报的异常检测方法, 如 PRIME-TR、COPOD、PCA-T² 和 EWMA, 综合运行成本主要由误报数量决定, 因此, 在不同 β/α 条件下总体保持稳定。相比之下, 温度阈值和电压阈值方法由于存在漏报, 其综合运行成本随 β/α 的增加而上升。

在整个权重区间内, PRIME-TR 始终保持最低综合运行成本, 说明该框架能够在误报控制与安全敏感性之间取得更优平衡。实验中采样频率为 1 Hz, 因 $\tau=60$ 对应约 60 s 的持续越阈判定窗口, 具有明确工程时间尺度。

4.5 事件级提前预警能力验证

在完成正常运行稳定性和泛化能力验证后, 进一步评估 PRIME-TR 在 TR 事件场景中的提前预警能力。分析分为两个层面:

a. 单样本风险演化分析, 用于说明风险评分与内部结构演化之间的对应关系;

b. 统一对比测试, 用于在一致评价口径下比较不同方法的事件级预警表现。

4.5.1 NBFD 事件级验证中的参考时刻定义

实验数据选取自 NBFD 电池故障数据库^[17], 其中包含热诱导失效事件记录和高速 X 射线成像视频。本文从中选取了 12 个事件样本, 电芯类型为 18650 型锂离子电池, 触发机制为热触发 (heater ISC), 充电状态为满充 (即荷电状态为 100%)。内部结构动态通过 X 射线视频记录, 像素大小约 10 μm , 用于观察失效过程中电芯内部反应区的快速演化。温度和加热条件仅为实验控制范围或参




图 8 持续触发决策机制下的成本敏感性分析

Fig.8 Cost sensitivity analysis under the continuous trigger decision-making mechanism

考值。基于该数据，本文在事件级验证中采用基于内部结构演化的参考时刻，以更细粒度界定不可逆失效阶段的起点。该参考时刻仅用于 NBFD 事件级验证中的物理对齐分析，是第 1.5 节工程评估定义的补充，而非替代。

具体地，将事件级参考时刻定义为电芯内部不可逆反应区开始持续扩展的最早时刻，即：

$$t_{\text{TR}}^{\text{event}} = \inf \{t \mid \Omega(t) = 1\} \tag{13}$$

式中， $\Omega(t)$ 为不可逆反应区持续扩展的判据函数。当 X 射线图像中观察到电芯内部反应区由局部热驱动阶段转入持续扩展阶段时，取 $\Omega(t)=1$ ，否则取 0。相较于首次排气或壳体破裂等外部现象，该时刻更接近内部失效机制的关键转折，因此被用作本节事件级分析的参考基准。

基于该定义，事件级提前预警时间定义为

$$t_L^{\text{event}} = t_{\text{TR}}^{\text{event}} - t_{\text{alarm}} \tag{14}$$

式中， t_{alarm} 表示系统首次触发稳定报警的时间。该指标用于量化预警系统相对于内部持续扩展起点所提供的提前量。

4.5.2 事件级风险演化分析

图 9 展示了单个 TR 事件样本中 $R(t)$ 、报警状态以及安全裕度 $R(t)-\theta$ 的演化过程，用于说明 PRIME-TR 在失效临近阶段的动态响应特征。

从图 9 可以看出，在参考失效时刻到来之前， $R(t)$ 已出现持续抬升，并在超过 θ 且满足持续触发条件后输出报警。报警状态和安全裕度曲线进一步表明，PRIME-TR 响应的是与内部结构演化相关的连续风险积累，而非单次外部可观测突变。

在该示例事件中，系统首次触发稳定报警的时间为 $t_{\text{alarm}}=35\ 980.68\ \text{s}$ ，相应事件级参考时刻为 $t_{\text{TR}}^{\text{event}}=35\ 981.35\ \text{s}$ ，二者之间的时间间隔约为 $0.67\ \text{s}$ 。结果表明，在单样本局部演化层面，PRIME-TR 能够在内部反应区进入持续扩展阶段之前给出稳定报警。

4.5.3 事件级预警结果对比与分析

为比较不同方法在 TR 事件场景中的预警能力，本文在统一对比测试设置下对各方法的事件级提前预警表现进行了比较，结果见表 5。图 9 所示 $0.67\ \text{s}$ 为基于单样本 X 射线视频嵌入时间轴得到的局部演化示例，用于说明机制；表 5 所示 $0.366\ 7\ \text{min}$ (约 $22\ \text{s}$) 为统一对比测试框架下基于真实实验时间轴换算得到的事件级 t_L ，用于方法间




图 9 TR 事件中风险评分与预警触发过程
Fig.9 Risk scoring and early warning triggering process in TR events

统一比较。

在统一评价口径下，表 5 中各方法的 t_L 均以同一事件参考时刻计算。结合原始 X 射线视频逐帧复核结果，本文将内部反应传播起点对应的真实实验时刻统一取为 $t_{\text{TR}}=28\ \text{s}$ 。视频画面中的嵌入时间轴仅用于局部过程可视化，不作为表 5 的直接计算基准。

从表 5 可见，阈值型方法的事件级提前量最小，异常检测方法整体表现出更强的提前识别能力，其中多变量方法优于单变量方法。PRIME-TR 取得最大的 t_L ，为 $0.366\ 7\ \text{min}$ (约 $22\ \text{s}$)，说明其能够在统一参考时刻之前更早给出稳定报警。

综合图 9 与表 5 可知，PRIME-TR 在该 TR 事件场景下既能够体现与内部结构演化一致的风险累积响应，也能够统一评价口径下获得更优的事件级提前预警表现。

4.6 系统级可部署性与误报控制

为评估 PRIME-TR 在大规模储能系统中的部署稳定性，本文基于 CALCE A123 LiFePO_4 电池 DST 正常运行数据构建虚拟机柜并行评估框架。通过 $1\ \text{Hz}$ 重采样和滑动窗口切分获得稳定运行片

表 5 热诱导失效环境下的 t_L 对比

Tab.5 t_L comparison under thermally induced failure

方法类别	方法名称	t_L/min
阈值型方法	温度阈值	0.066 7
阈值型方法	电压阈值	0.050 0
单变量异常检测	EWMA	0.166 7
单变量异常检测	Isolation Forest (single)	0.216 7
多变量异常检测	PCA-T ²	0.266 7
多变量异常检测	COPOD	0.300 0
本文方法	PRIME-TR	0.366 7

段池(片段长度为 4 h, 滑动步长为 2 h), 随机抽样 500 个片段模拟 500 个电芯并行运行。单体层独立计算 $R(t)$ 并执行持续触发判据, 机柜层进一步引入空间聚合与时间门控机制, 以统计系统级误报事件率。该框架不依赖新增硬件和模型重训练, 用于考察单体算法扩展到系统场景后的误报控制能力。

4.6.1 规模扩展能力分析

在合理单体参数设置($\theta=0.85$ 、 $\tau_{\text{cell}}=60\text{ s}$ 、 $N=500$)下, 20 组随机机柜实验均得到机柜级报警事件率为 0 次/d, 表明在正常运行条件下, 系统误报不会随规模扩展而明显放大, 单体层持续触发机制为系统级误报控制提供了基础。

4.6.2 同步瞬态扰动与时间门控抑制机制

在压力测试配置($\theta=0.60$ 、 $\tau_{\text{cell}}=10\text{ s}$ 、 $N=500$)下, 仅采用空间聚合(5% 投票)时, 系统误报达到机柜级报警事件率为 1 638 次/d, 说明在动态工况下, 多电芯同步短时越阈会引起显著的系统级误报放大。

进一步引入机柜层持续时间门控后, 误报率随 τ_{rack} 增大呈阶梯式下降: 当 $\tau_{\text{rack}}=10\text{ s}$ 时, 机柜级报警事件率降至 210 次/d; 当 $\tau_{\text{rack}}=20\text{ s}$ 时, 机柜级报警事件率进一步降至 30 次/d。相较于未引入时间门控时的 1 638 次/d, 误报下降约 98.2%。

这表明, 系统级误报放大主要来自共模瞬态扰动, 而决策层时间门控能够有效滤除短时同步结构误差叠加, 无需调整单体模型即可显著提升系统级输出稳定性。

4.6.3 统计稳健性分析

在 20 组随机构造下, 最优配置($\theta=0.60$ 、 $\tau_{\text{cell}}=10\text{ s}$ 、 $p=5\%$ 、 $\tau_{\text{rack}}=20\text{ s}$)的误报分布为: 平均为 37.5 次/d, 中位数为 36.0, $p_{95}=42.3$, 最小值/最大值为 24/48。误报区间收敛且波动范围有限, 说

明该决策层时间门控机制在不同抽样结构下均保持稳定表现, 具有较好的统计稳健性。

5 结 论

本文提出了一种面向储能系统 TR 预警的风险映射与持续触发决策框架 PRIME-TR。该框架在不增加额外传感器的条件下, 基于 BMS 可获取的多变量时序数据, 通过“异常感知—风险映射—持续触发”三阶段结构, 实现了异常评分向工程预警决策的分层转换。主要结论如下:

a. 融合物理模型残差的多变量时序表示能够增强对复杂运行演化模式的刻画能力, 为后续风险评估提供更具判别性的输入。

b. 基于经验分布函数的风险映射机制将原始异常评分统一到分位语义空间, 使固定阈值在 DST、FUDS 及跨电芯场景下保持稳定判定结果, 并在正常运行阶段实现 0 误报。

c. 持续触发决策通过时间一致性约束抑制瞬态越阈造成的短时误触发, 在不同安全偏好权重下均表现出较低的综合运行成本。

d. 在统一事件级评价口径下, PRIME-TR 相对于电芯内部不可逆结构持续扩展参考时刻实现了 0.366 7 min(约 22 s)的提前预警, 优于温度阈值、电压阈值、EWMA、Isolation Forest、PCA-T² 和 COPOD 等对比方法。

e. 虚拟机柜并行评估表明, 在合理门控参数设置下, 系统误报未随规模扩展而明显放大; 在压力测试条件下, 决策层时间门控可显著抑制同步瞬态扰动引起的误报叠加, 并在 $N=500$ 规模下保持较好的统计稳健性。

本文所采用的事件级提前量基于电芯内部不可逆结构持续扩展参考时刻计算, 主要用于统一性能评估, 不直接等同于系统层面的实际处置时间。后续工作将结合多电芯耦合传播模型与真实储能运行数据, 进一步验证 PRIME-TR 在系统级联失效场景中的适用性, 并分析其与主动安全控制策略的协同关系。同时, PRIME-TR 框架虽不限定具体异常检测器, 但检测器类型仍会影响最终预警性能: 单变量检测器实现简单、计算成本低, 适用于低动态或资源受限场景; 多变量检测器对变量耦合异常更敏感, 更适合高动态或多电芯系统。实际部署中, 可根据系统动态特性、数据质量和计算资源选择检测器, 并通过风险映射

与持续触发机制提升预警决策的稳健性与一致性。

参考文献:

- [1] FENG X N, OUYANG M G, LIU X, et al. Thermal runaway mechanism of lithium ion battery for electric vehicles: a review[J]. *Energy Storage Materials*, 2018, 10: 246–267.
- [2] SPOTNITZ R, FRANKLIN J. Abuse behavior of high-power, lithium-ion cells[J]. *Journal of Power Sources*, 2003, 113(1): 81–100.
- [3] FINEGAN D P, SCHEEL M, ROBINSON J B, et al. In-operando high-speed tomography of lithium-ion batteries during thermal runaway[J]. *Nature Communications*, 2015, 6: 6924.
- [4] LARSSON F, ANDERSSON P, BLOMQVIST P, et al. Toxic fluoride gas emissions from lithium-ion battery fires[J]. *Scientific Reports*, 2017, 7(1): 10018.
- [5] REN D S, LIU X, FENG X N, et al. Model-based thermal runaway prediction of lithium-ion batteries from kinetics analysis of cell components[J]. *Applied Energy*, 2018, 228: 633–644.
- [6] 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: 0008.
- [7] LIU K L, LI K, PENG Q, et al. A brief review on key technologies in the battery management system of electric vehicles[J]. *Frontiers of Mechanical Engineering*, 2019, 14(1): 47–64.
- [8] PESARAN A A. Battery thermal models for hybrid vehicle simulations[J]. *Journal of Power Sources*, 2002, 110(2): 377–382.
- [9] RAIJMAKERS L H J, DANILOV D L, EICHEL R A, et al. A review on various temperature-indication methods for Li-ion batteries[J]. *Applied Energy*, 2019, 240: 918–945.
- [10] HU X S, ZHANG K, LIU K L, et al. Advanced fault diagnosis for lithium-ion battery systems: a review of fault mechanisms, fault features, and diagnosis procedures[J]. *IEEE Industrial Electronics Magazine*, 2020, 14(3): 65–91.
- [11] KOUHESTANI H S, LIU L, WANG R M, et al. Data-driven prognosis of failure detection and prediction of lithium-ion batteries[J]. *Journal of Energy Storage*, 2023, 70: 108045.
- [12] SUSTO G A, SCHIRRU A, PAMPURI S, et al. Machine learning for predictive maintenance: a multiple classifier approach[J]. *IEEE Transactions on Industrial Informatics*, 2015, 11(3): 812–820.
- [13] LIU F T, TING K M, ZHOU Z H. Isolation forest[C]//Proceedings of the 2008 Eighth IEEE International Conference on Data Mining. Pisa: IEEE, 2008: 413–422.
- [14] ZHAO B, ZHANG W G, ZHANG Y R, et al. Lithium-ion battery remaining useful life prediction based on interpretable deep learning and network parameter optimization[J]. *Applied Energy*, 2025, 379: 124713.
- [15] ZIO E. Reliability engineering: old problems and new challenges[J]. *Reliability Engineering & System Safety*, 2009, 94(2): 125–141.
- [16] Center for Advanced Life Cycle Engineering (CALCE). Battery data[EB/OL]. University of Maryland[2026-03-21]. <https://calce.umd.edu/battery-data>.
- [17] National Laboratory of the Rockies (NLR). Battery failure databank[EB/OL]. [2026-03-21]. <https://www.nlr.gov/transportation/battery-failure.html>.
- [18] KONG D P, LV H P, PING P, et al. A review of early warning methods of thermal runaway of lithium ion batteries[J]. *Journal of Energy Storage*, 2023, 64: 107073.
- [19] LI Y X, JIANG L H, ZHANG N J, et al. Early warning method for thermal runaway of lithium-ion batteries under thermal abuse condition based on online electrochemical impedance monitoring[J]. *Journal of Energy Chemistry*, 2024, 92: 74–86.
- [20] XIE Z Y, ZHANG Y, WANG H, et al. The multi-parameter fusion early warning method for lithium battery thermal runaway based on cloud model and Dempster-Shafer evidence theory[J]. *Batteries*, 2024, 10(9): 325.
- [21] TENG Z F, LV C. Detection toward early-stage thermal runaway gases of Li-ion battery by semiconductor sensor[J]. *Frontiers in Chemistry*, 2025, 13: 1586903.
- [22] VU L A, HONG H S, QUANG L T, et al. A real-time framework for early detection and severity prediction of thermal runaway in Li-ion batteries[J]. *Journal of Energy Storage*, 2025, 135: 118310.
- [23] 朱鹏杰, 李伟, 张楚, 等. 基于烟气扩散的储能柜内锂电池热失控预警研究[J]. *储能科学与技术*, 2025, 14(2): 624–635.
- [24] 马敬轩, 赖银麟, 吕娜伟, 等. 锂离子电池智能传感监测及预警技术[J]. *电工技术学报*, 2025, 40(3): 941–963.
- [25] 谭则杰, 周晓燕, 徐振恒, 等. 锂离子电池热失控监测与预警的气敏技术研究进展[J]. *储能科学与技术*, 2023, 12(11): 3456–3470.
- [26] 孟国栋, 李雨珮, 唐佳, 等. 锂离子电池储能电站的热失控状态检测与安全防控技术研究进展[J]. *高电压技术*, 2024, 50(7): 3105–3127.
- [27] SULZER V, MARQUIS S G, TIMMS R, et al. Python battery mathematical modelling (PyBaMM)[J]. *Journal of Open Research Software*, 2021, 9(1): 14.

(编辑: 何代华)