



基于异常特征自适应增强方法的 锂离子电池故障诊断研究

蔡泽阳¹, 张 良², 杨世春¹, 王金明³, 闫啸宇⁴

(1.北京航空航天大学 交通科学与工程学院, 北京 100191; 2.应急管理部天津消防研究所, 天津 300381; 3.江苏永贵新能源科技有限公司, 江苏 南京 210038; 4.北京航空航天大学 航空发动机研究院, 北京 100191)

摘要: 在交通运输领域, 电池管理系统对保障大容量锂离子电池安全性和稳定性具有至关重要的作用。电池安全预警是电池管理系统(BMS)的核心功能之一, 传统的电池安全预警算法主要基于直接参数检测方法实现, 但由于早期故障电池的电压、电流、温度信号变化不明显, 因此该方法预警时间短、误报率高。为解决该问题, 文章首先针对动力电池系统的风险预警提出安全熵的概念, 以此量化评估其安全风险; 然后基于安全熵构建了融合电池系统故障动态权重的动力电池系统安全预警算法, 与传统方法相比, 该方法能够实现电池系统风险的早期量化评估; 最后使用新能源汽车历史事故数据以及新能源汽车-充电桩协同数据进行了算法有效性验证, 验证结果表明该算法能够有效识别电池安全风险, 并实现提前7天发出风险预警。文章提出的安全熵模型及自适应动态权重机制也可为轨道交通车辆的大容量锂离子电池系统安全监控提供新的方案, 提升早期风险预警能力。

关键词: 动力电池; 风险预警; 故障诊断; 新能源交通

中图分类号: U267.1

文献标志码: A

文章编号: 1000-128X(2025)03-0048-08

0 引言

动力电池因其高能量密度和高输入输出功率等优势已成为新能源交通工具能源系统的核心组件之一。随着新能源交通工具在我国交通运输系统中占比的逐年提升, 动力电池系统的可靠性与安全性问题日益凸显, 其中由电池长期劣化导致的热失控起火事故已造成大量人身财产损失, 因此热失控故障的提前识别对保障动力电池系统使用安全具有重要意义。当前动力电池故障识别主要存在两项技术瓶颈: 其一, 电池劣化过程缺乏明显的宏观特征表现, 电池的电压、温度等参数在热失控超早期阶段仍可能保持稳定, 这导致传统阈值预警机制存在漏报率高的问题^[1-2]; 其二, 电池热失控故障是由多重

失效原因耦合作用导致的, 其中包括电化学性能衰退、内短路、连接件老化等, 而现有检测技术在早期故障识别方面灵敏度不足^[3-4]。针对上述问题, 专家学者从直接参数检测、基于模型的诊断和基于智能算法的预警3个方面提出了不同的解决思路^[5]。

直接参数检测方法的核心思想是针对被检测指标设定固定阈值, 并基于阈值识别故障电池, 文献[6]开展了针对电压、温度、气压、特征气体和挥发性有机化合物、膨胀力以及烟雾的检测, 并基于此进行了6种电池热失控预警方案及原理对比, 结果表明基于电压、温度和特征气体等信息可在一定程度上实现电池热失控识别, 且基于特征气体的电池热失控识别方案误报率相对较低。总体来说, 直接参数检测方法的热失控识别逻辑简单, 但容易产生误报^[7]。

基金项目: 国家自然科学基金项目(52476172); 中央高校基本科研业务费专项资金(501QYJC2025146001)

通信作者: 杨世春, 男, 博士, 教授, 北京航空航天大学交通科学与工程学院院长, 从事车辆工程学科科研与教学工作; E-mail: yangshichun@buaa.edu.cn

引用格式: 蔡泽阳, 张良, 杨世春, 等. 基于异常特征自适应增强方法的锂离子电池故障诊断研究[J]. 机车电传动, 2025(3): 48-55.DOI:10.13890/j.issn.1000-128X.2025.03.006.

Citation: CAI Zeyang, ZHANG Liang, YANG Shichun, et al. Research on fault diagnosis of lithium-ion batteries based on adaptive boosting of abnormal features[J]. Electric drive for locomotives, 2025(3): 48-55.DOI:10.13890/j.issn.1000-128X.2025.03.006.

基于模型的诊断方法通过建立表征电池内部状态或外部特性的数学模型, 采用参数辨识和残差生成等技术实现故障检测与定位, 有效克服了直接测量方法的局限性^[8]。该方法主要包括基于电化学机理模型的状态估计方法和基于等效电路模型的参数辨识方法^[9]。基于电化学机理模型的方法通过对电池失效机理进行数学建模, 构建热失控风险边界来实现风险识别, 该方法可基于热失控机理推演电池当前及未来状态, 实现早期诱因识别, 但存在模型复杂度高、计算量大的缺点^[10]。基于等效电路模型的方法通过构建不同故障模式的等效电路模型实现参数辨识, 典型模型包括内短路故障^[11]等效电路模型、析锂故障^[12]等效电路模型, 该方法具有模型结构简单、计算量小的优点, 但难以对不同风险模式建立统一描述。基于模型的方法有赖于对电池故障机理的深入理解, 且在电池全生命周期中需持续维护模型参数, 导致成本较高^[13]。

基于上述分析, 相关研究人员通过智能算法研究电池热失控触发前数据特征, 提取关键风险因子, 构建风险电池与正常电池的区别边界^[14-15]。文献[16]通过分析热失控故障电池的电化学阻抗谱信号, 提取了电池超早期热失控特征, 并使用机器学习方法构建了基于DBSCAN算法的热失控识别模型, 可在电池起火前15 min实现预警; 文献[17]提出了一种融合卷积神经网络与长短期记忆网络的智能热诊断方法, 通过将计算获取的残差信号与预设的故障阈值进行比对实现故障诊断。智能算法在电池热失控诊断方面效果良好^[18-19], 该方法采用非线性映射技术将电池特征参数转换至高维空间, 实现正常与异常电池的有效分类, 具有融合多维特征共同进行预警诊断的优势, 但模型训练需要大规模样本数据, 且由于缺乏电化学机理约束, 部分算法呈现黑盒模型, 决策过程可解释性不足。

本文将从概率角度出发, 结合信息熵方法论, 构建动力电池安全熵物理模型, 实现电池热失控风险预警; 考虑不同热失控诊断指标对电池不同老化程度下热失控故障的表征能力不同, 引入了动态指标权重; 解决了基于机理模型的热失控诊断方法对模型精度的依赖以及智能预警算法输出结果可解释性不足的问题, 同时与传统方法相比大大提升了风险预警的时效性和风险识别精度。

1 多故障融合的电池安全熵风险评估模型

安全熵是一种针对系统安全性的量化评估方法, 使用安全熵能够依据系统发生故障的概率(或完全安全功能的概率)描述系统安全性。对于某系统安全事件 x , 其事故发生概率可用 $P(x)$ 表示, 由于概率密度分析通常需要基于大量随机事件, 无法直接描述系统安全性, 因此, 从熵的角度分析, 通过采用与概率密度相似的安全熵来描述系统内各安全因素的不确定度、混乱度等, 可实现对系统安全性的定量描述。通常情

况下, 系统的安全熵越大, 不安全性越小。安全熵的基本定义为

$$S(x) = k \log \frac{1}{P(x)} = -k \log P(x) \quad (1)$$

式中: $S(x)$ 为系统的安全熵; k 为待定系数或归一系数; $P(x)$ 为事件安全概率密度。

根据上述式(1), k 的符号决定了安全熵的使用条件。当 k 为负数时, 安全度 $P(x)$ 越大, 对应的安全熵 $S(x)$ 越大; 当 $P(x)=1$ 时, 对应的安全熵 $S(x)$ 达到最大值, 此时 $S(x)=0$, 说明该安全因素混乱度最大。同理, 安全度 $P(x)$ 越小, 对应的安全熵 $S(x)$ 越小, 说明该安全因素混乱度越小, 执行该安全功能的能力就越强。

安全熵虽在原理上实现了对安全度的量化, 但在实际使用中会遇到多种情况, 主要包括系统安全度由多个事件描述、不同事件对安全度贡献程度不同、概率值存在奇点(概率为0)的情况、部分事件不能使用概率值描述等, 因此实际使用的安全熵定义需进行不同程度的扩展。

1) 由多个事件组成的安全熵

当系统安全度由多个独立事件共同描述时, 基于独立事件概率密度计算方法, 根据联合概率等于各个独立事件概率乘积, 可得出

$$P(x | x_1, x_2, \dots, x_n) = P(x_1)P(x_2) \cdots P(x_n) \quad (2)$$

结合安全熵定义得出由多个独立事件组成的系统安全熵为

$$S(x) = -k \log P(x_1)P(x_2) \cdots P(x_n) = -k(\log P(x_1) + \log P(x_2) + \cdots + \log P(x_n)) = \sum_{i=1}^n -k \log P(x_i) \quad (3)$$

2) 自定义权重的安全熵

考虑每个独立事件在系统安全方面的贡献不一致, 其待定系数或归一系数应不相同, 以此可实现对不同事件的区分评价。权重值可以根据经验选取, 对温度值(区间)、BMS上报的次要故障等赋予较小的固定权重, 而对自放电率、最低电压单体分布、电压差、温度差等重要且随动力电池老化而逐渐变化的参数, 则可使用自适应权重。

在实际应用中, 随着电池的老化, 电池电压、电流、产热及温度等宏观参数表征与未老化电池相比会发生偏移, 单一指标权重分布形式无法反映电池相关特征在全生命周期的演化规律, 因此本文将电池管理系统输出的电池健康状态SOH(state of health)值作为电池老化程度的评判依据, 基于给定的SOH初始值和结束值采用式(4)计算权重, 可实现从不同SOH阶段获得不同程度的权重值加成。多特征线性耦合的权重为

$$\alpha = \frac{A_{\text{SOH}0} - A_{\text{SOHCur}}}{1 + ((A_{\text{SOH}0} - A_{\text{SOH}n}) / (f \cdot A_{\text{SOH}0} A_{\text{SOH}n})) \cdot A_{\text{SOH}j}} \quad (4)$$

式中: $A_{\text{SOH}0}$ 为初始电池健康状态值; $A_{\text{SOH}n}$ 为老化末尾电池健康状态值; A_{SOHCur} 为当前电池健康状态值;

A_{SOH_j} 为中间变量; f 为调节参数。

由式(4)可知, 在电池老化初期权重值较小, 表明此时电池自放电率、电压差等参数与其他参数有相似的重要性; 随着电池不断老化, 在接近老化末尾时该权重值快速增大, 表明此时该类参数的作用被放大, 权重提高。

3) 概率值为奇点的优化

能使用概率描述的事件可能存在概率为 0 的情况, 如最低电压分布等。在对数函数计算时概率为 0 的事件其对数为无穷大, 无法用于实际计算。因此对计算安全熵的概率密度进行优化, 增添补偿项以保证概率值在计算对数时有效。安全熵的定义可扩展为

$$S(x) = -k \log(1+x) \quad (5)$$

4) 不能直接使用概率描述的事件

在对电池系统的安全度进行量化时, 某些特征量无法使用概率描述, 主要包括最大电压差、最大温度差等。无法采用概率描述的事件可通过附加常量进行归一化表征, 表示形式为

$$S(x) = - \sum_{i=1}^n b_i \quad (6)$$

式中: b_i 为非概率事件贡献的安全熵常量。

综上所述, 考虑各个因素后优化安全熵, 得到能实际应用的安全熵表达式为

$$S = - \sum_{i=1}^m \alpha_i \log(a + P(x_i)) - \sum_j^n b_j \quad (7)$$

式中: α_i 为自适应权重; a 为补偿值; $P(x_i)$ 为第 i 个事件的概率。

2 面向实际场景的多故障特征权重动态分配机制

2.1 基于历史事故数据的动力电池安全特征

基于上述安全熵定义及计算方法, 考虑其实际应用主要集中在对安全相关事件的描述中, 本文通过知识推理与故障数据反演方法提取了电池安全预警相关特征, 最终形成指示型和间接影响型两类共计 21 个指标的安全熵特征集群, 具体如表 1 所示。对于如最高电

表 1 安全特征定义与计算公式

Table 1 Definition and computational formulae of safety features

编号	特征名称	特征计算公式	特征类型
1	最高单体电压	$V_{\max} = \max\{V_1, V_2, \dots, V_n\}$	指示型特征
2	最低单体电压	$V_{\min} = \min\{V_1, V_2, \dots, V_n\}$	指示型特征
3	单体电压不一致性	$V_{\text{inc}} = \max\{V_i - V_j\}$	指示型特征
4	单体最高平均电压	$V_{s, \max} = \max\{V_1, V_2, \dots, V_n\}$	指示型特征
5	单体最低平均电压	$V_{s, \min} = \min\{V_1, V_2, \dots, V_n\}$	指示型特征
6	系统电压	$V_{\text{pack}} = \sum V_i$	指示型特征
7	最低电压单体数统计	$p = \max(p_i(V_{\min})/n)$	指示型特征
8	最高电压单体数统计	$p = \max(p_i(V_{\max})/n)$	指示型特征
9	充电效率	$\eta = \frac{W_{\text{dis}}}{W_{\text{ch}}}$	指示型特征
10	最高单体温度	$T_{\max} = \max\{T_1, T_2, \dots, T_n\}$	指示型特征
11	最低单体温度	$T_{\min} = \min\{T_1, T_2, \dots, T_n\}$	指示型特征
12	单位能量输出温升	$\dot{T}_E = \frac{dT}{dE} = \frac{\Delta T}{\Delta E}$	指示型特征
13	最高温升速率	$\dot{T} = \frac{dT}{dt} = \frac{\Delta T}{\Delta t}$	指示型特征
14	系统温度不一致性	$T_{\text{inc}} = \max\{V_i - V_j\}$	指示型特征
15	时间片段内系统平均温度	$\bar{T} = \left(\sum_{i=1}^n T_i \right) / n$	指示型特征
16	最低温度单体数统计	$p = \max(p_i(T_{\min})/n)$	指示型特征
17	最高温度单体数统计	$p = \max(p_i(T_{\max})/n)$	指示型特征
18	充电深度	$D = A_{\text{SOC end}} - A_{\text{SOC begin}}$	影响型特征
19	单体最大 A_{SOH}	$A_{\text{SOH max}} = \max(A_{\text{SOH}})$	影响型特征
20	单体最小 A_{SOH}	$A_{\text{SOH min}} = \min(A_{\text{SOH}})$	影响型特征
21	单体 SOH 衰退速率	$\dot{A}_{\text{SOH}} = \frac{dA_{\text{SOH}}}{dt} = \frac{\Delta A_{\text{SOH}}}{\Delta t}$	影响型特征

压、最高温度、总电压、绝缘电阻等指示型指标, 指标的超限表征了电池内部存在一定程度的故障及安全风险, 可用于直接预警; 而对于电池老化状态等影响型指标, 主要用于分析电池全生命周期的衰退和不同环境安全特征的演变情况。

2.2 基于事故数据的特征影响因子更新算法

可用于研究电池安全性的特征已有21个, 而如何合理组合所有特征成为主要问题, 因此该问题转化为根据每个特征的熵尺度确定其动态权重。本研究针对不同的条件, 提出了两种不同的权值。

第一种动态权值是根据热失控机理和相关经验构建的基于知识的权值, 其关联权值也可设计为带有某些参数的函数。这些权重大多是恒定的, 某些时候与电池状态或退化有关, 可以用其他权重函数进一步扩展, 如表2所示。各权重的最终结果具有相同的尺度, 但当熵与自身权重相结合时, 最终结果可能呈现出较大的变化, 这证实了各特征对安全的影响程度。这种权值主要用于有限数据范围内的电池故障诊断, 如几小时或几天, 无法提取历史进化路径来优化权重的选择。第二类权值是基于历史数据实现对权重的计算, 同时可进一步依靠经验或知识进行处理。

表2 安全特征权重定义及边界值

Table 2 Definition of safety feature weights and boundary values

编号	特征名称	符号	权重函数类型	权重计算公式	权重下限	权重上限
1	最高单体电压	V_{\max}	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	3
2	最低单体电压	V_{\min}	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	3
3	单体电压不一致性	V_{inc}	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	3
4	单体最高平均电压	\bar{V}	Sigmoid 函数	$w_i = \frac{a}{1 + e^{-b(x_i - \bar{x})}}$	0	1
5	单体最低平均电压	\bar{V}	Sigmoid 函数	$w_i = \frac{a}{1 + e^{-b(x_i - \bar{x})}}$	0	1
6	系统电压	$V_{s, \max}$	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	3
7	最低电压单体数统计	$p_{v \min}$	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	1	2
8	最高电压单体数统计	$p_{v \max}$	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	1	2
9	充电效率	η	Sigmoid 函数	$w_i = \frac{a}{1 + e^{-b(x_i - \bar{x})}}$	0.9	1
10	最高单体温度	T_{\max}	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	3
11	最低单体温度	T_{\min}	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	2
12	单位能量输出温升	\dot{T}_E	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	1	2
13	最高温升速率	\dot{T}	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	3
14	系统温度不一致性	T_{inc}	指数函数	$w_i = ae^{-b(x_i - \bar{x})}$	1	3
15	时间片段内系统平均温度	\bar{T}	Sigmoid 函数	$w_i = \frac{a}{1 + e^{-b(x_i - \bar{x})}}$	0	1
16	最低温度单体数统计	$p_{T \min}$	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	1	2
17	最高温度单体数统计	$p_{T \max}$	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	1	3
18	充电深度	D	指数函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	0	1
19	单体最大 A_{SOH}	$A_{\text{SOH} \max}$	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	0	3
20	单体最小 A_{SOH}	$A_{\text{SOH} \min}$	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	0	3
21	单体 SOH 衰退速率	\dot{A}_{SOH}	Softmax 函数	$w_i = \frac{e^{x_i - \bar{x}}}{\sum e^{x_i - \bar{x}}}$	0	3

本文涉及的权重主要包含3种类型——指数函数权重、Sigmoid 函数权重、Softmax 函数权重。其中,

指数函数权重主要用于关键特征发生异常时的权重增强, 当自变量超出预设区间时, 指数函数将快速放大

权重值以提升样本权重的比例,从而凸显异常特征,使安全熵曲线产生尖峰。Sigmoid函数和Softmax函数具有权重值在接近0时趋于0,超出预设区间后则趋于1的特性,主要用于影响型特征对其他类型特征的修正,例如电池SOH采用该权重后,新电池权重接近其下限,电池老化后权重接近其上限,从而放大这一特征对安全熵的贡献率。

3 基于新能源汽车历史事故数据的安全风险预警算法验证

本章使用2400余辆新能源汽车云端数据进行基于历史事故数据的安全风险预警算法有效性验证,数据规格符合GB/T 32960—2015对电动汽车总体实时信息监控的要求,算法指标采用了本文2.1与2.2节中构建的部分预警特征(其余部分特征无法计算)。测试数据涵盖了大量的正常车与小样本的异常车。尽管验证数据来源于新能源汽车,但其核心算法架构可迁移至轨道交通等其他新能源交通工具应用场景。

1) 典型安全风险预警案例

基于某纯电动汽车1起火数据的安全风险预警结果如图1所示。该车于2020年9月23日17时19分起火,历史行程为124371 km,发生热失控的电池为第64号单体电芯。基于历史数据,本文模型在16时23分36秒提前报警。由图1可知,报警时刻64号电芯电压存在明显分层现象,系统电压不一致性达到0.24 V,表明车辆内部电芯存在性能严重劣化现象,本文模型预警结果准确。

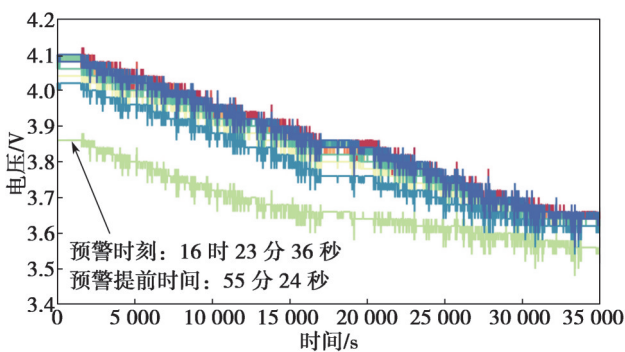


图1 某车型车辆1安全风险预警结果

Fig. 1 Early-warning results of safety risks for vehicle model 1

基于某纯电动汽车2起火数据的安全风险预警结果如图2所示。该车于2024年6月23日8时35分发生起火事故,发生热失控的电池为第65号单体电芯。基于历史数据,本文模型在当日16时16分16秒提前报警。由图2可知,报警时刻65号电芯电压突降0.12 V,表现出瞬态强不一致性,表明车辆内部电芯突然劣化、存在失效风险,本文模型预警结果准确。

基于某纯电动汽车3起火数据的安全风险预警结果如图3所示。该车于2020年7月8日1时31分起火,历




图2 某车型车辆2安全风险预警结果

Fig. 2 Early-warning results of safety risks for vehicle model 2

史行程为30057 km,发生热失控的电池为第118号单体电芯。根据历史数据,本文模型在1时29分24秒提前报警,报警时刻118号电芯电压突降达到0.15 V,系统电压不一致性达到0.24 V,表明车辆内部电芯突然劣化、存在失效风险,本文模型预警结果准确。




图3 某车型车辆3安全风险预警结果

Fig. 3 Early-warning results of safety risks for vehicle model 3

2) 云端大规模数据集安全风险预警模型测试

基于某电池企业提供的已发生过电池安全风险的车辆24辆和正常车辆2479辆的历史运行数据,构建了2503辆电动汽车运行数据集,其中故障车与正常车比例超过1:100,且每辆车的历史运行时间不短于7天。本文模型在测试集中测试时,共报警28例,误报5例。24辆已发生过电池安全风险的车辆测试结果如表3所示,其中正确报警23例、漏报1例。根据车辆的历史运行时间,车辆在算法报警后至少7天才出现电池安全风险,因此可知该算法可提前7天进行风险预警。

以智能算法常用的准确率和误报率为指标对本文算法进行评价,计算公式分别如式(8)、式(9)。

$$P_T = \frac{n_T}{n_{\text{sum}}} = \frac{23}{24} \approx 95.83\% \quad (8)$$

式中: P_T 为算法准确率; n_T 为正确识别的故障车辆数; n_{sum} 为测试数据集中故障车辆总数。

$$P_W = \frac{n_W}{N_{\text{sum}}} = \frac{5}{2503} \approx 0.1998\% \quad (9)$$

式中: P_W 为算法误报率; n_W 为数据集总误报车辆数; N_{sum} 为测试数据集中车辆总数。

结果显示算法在测试数据集中的准确率为95.83%,

表3 动力电池报警结果

Table 3 Results of power battery alarms

编号	故障车辆VIN编号	车辆故障类型	是否报警	编号	故障车辆VIN编号	车辆故障类型	是否报警
1	LJ1EEKPP3K7419567	热失控	是	13	LJ1EEKPP0K7413855	电芯浸水	是
2	LJ1EEKPP9K7414258	热失控	是	14	LJ1EEKPP4K7415947	电芯漏液	是
3	LJ1EEKPP6K7410605	热失控	是	15	LJ1EEKPP5K7411518	电芯漏液	是
4	LJ1EEKPP6K7413150	热失控	是	16	LJ1EEKPP0K7413225	电芯漏液	是
5	LJ1EEKPP1K7419549	热失控	是	17	LJ1EEKPP2K7410326	电压严重分层	是
6	LJ1EEKPP5L7400827	热失控	是	18	LJ1EEKPP2K7419446	电压严重分层	是
7	LJ3752CWOMA303734	热失控	否	19	LJ1EEKPP9L7400829	压差过大	是
8	LJ1EEKPP3K7414157	热失控	是	20	LJ1EEKPP9K7414549	压差过大	是
9	LJ1EEKPP2L7400283	电芯内部短路	是	21	LJ1EEKPP7K7407132	压差过大	是
10	LJ1EEKPP9K7418911	电芯内部短路	是	22	LJ1EEKPPXK7413913	温差过大	是
11	LJ1EEKPPXK7415063	电芯内部短路	是	23	LJ1EEKPPXK7414091	温差过大	是
12	LJ1EEKPP8L7400529	电芯浸水	是	24	LJ1EEKPP7K7408832	温差过大	是

误报率为0.199 8%。模型所具有的低误报率和高精度预警的性能, 满足新能源交通高安全、低误触发的运营及维护场景需求。


4 基于车桩协同数据的安全风险预警算法验证

本章基于500多个充电桩在2021年6月1日至2021年9月30日的充电记录数据, 开展了基于桩端数据的电池安全风险评价及预警算法验证研究。由于桩端记录数据的间隔, 数据量远低于新能源汽车云端监控平台, 因此采用了包括电压分布、最大电压、最小电压、电压不一致性、最高温度、温度分布、温度不一致性、生热速率、IC/DV曲线、剩余容量、自放电率、内阻、快充频率、SOC在内的14维特征进行预警算法的验证测试。


编号1140290000006010的快充桩在3个月内服务

用户的充电记录如图4(a)所示。记录的充电片段显示, 共对两位用户进行了预警, 根据安全熵的计算结果、特征贡献率分析及权重值的计算, 发现较大的电压和温度不一致性为主要预警原因, 其中用户1的电压不一致性达到0.15 V, 用户2的温度不一致性达到了16 °C。预警后可采用充电桩降功率运行或限制运行等方式进行安全管控。


编号1140290000001280和1140290000004070的快充桩在3个月内服务用户的充电记录如图4(b)和图4(c)所示。记录的充电片段显示, 未对用户发送预警, 但对安全熵值超过15的多位用户充电行为进行了持续监控, 通过对特征贡献率的分析和权重函数权值大小的比较发现, 用户存在充电时间过长的的问题, 因此电池系统可能存在潜在安全风险或控制不当行为。充电行为监控后可采用充电桩降功率运行等方式进行安全管控。



(a) 充电桩1数据验证



(b) 充电桩2数据验证



(c) 充电桩3数据验证

图4 基于桩端数据的动力电池安全风险预警算法验证

Fig. 4 Validation of algorithm for early warning of power battery safety risks based on data from charging stations

5 结束语

电池管理系统作为新能源交通工具能源系统的大脑，其电池风险识别算法是保证电池系统以及新能源汽车安全运行的关键。传统的风险识别算法主要依赖于对电压、电流、温度等电池系统信号的直接测量，导致风险预警时间短，误报率高。本文提出的新的电池风险预警方法，能够在保证预警精度的同时实现对电池风险的超前感知。通过引入安全熵，借助电池发生故障概率实现了对电池潜在风险的量化评估；为准确反映电池不同老化程度、不同故障类型对其安全性的不同影响程度，通过知识推理、故障数据反演提取了电池安全预警相关故障特征，设计了基于故障模式的动态权重赋予机制；通过将安全熵与动态权重分配机制有机融合，提出了多故障融合的电池安全熵风险评估模型；基于新能源汽车历史事故数据和车桩协同数据完成了算法有效性验证，结果显示本文算法在保证精度的同时实现超前预警。

本文所提出的电池故障诊断与预警方法，不仅适用于新能源汽车，也为构建更安全的绿色轨道交通能源系统提供了技术基础和解决方案。

参考文献：

- [1] TANG Guowei, MEN Libo, WANG Yilin, et al. Lithium deposition mechanism under different thermal conditions unraveled via an optimized phase field model[J]. Nano letters, 2025, 25(6): 2561-2567.
- [2] WANG Yaxuan, LI Junfu, GUO Shilong, et al. Parameter sensitivity analysis of a multi-physics coupling aging model of lithium-ion batteries[J]. Electrochimica acta, 2024, 477: 143811.
- [3] GUO M, WHITE R E. A distributed thermal model for a Li-ion electrode plate pair[J]. Journal of power sources, 2013, 221: 334-344.
- [4] LI J, ADEWUYI K, TECHNOLOGY R, LOTFI N, et al. A single particle model with chemical/mechanical degradation physics for lithium ion battery state of health(SOH) estimation[J]. Applied energy, 2018, 212: 1178-1190.
- [5] 张扬. 基于数据驱动的电动汽车动力电池故障诊断方法研究[D]. 太原: 中北大学, 2024.
ZHANG Yang. Research on data-driven fault diagnosis method for electric vehicle power battery[D]. Taiyuan: North University of China, 2024.
- [6] 秦李伟, 姜点双, 徐爱琴, 等. 锂离子动力电池系统热失控检测原理及方案[J]. 汽车电器, 2024(3): 17-19.
QIN Liwei, JIANG Dianshuang, XU Aiqin, et al. The principle and scheme of thermal runaway detection for lithium-ion power battery systems[J]. Auto electric parts, 2024(3): 17-19.
- [7] 庞辉. 基于扩展单粒子模型的锂离子电池参数识别策略[J]. 物理学报, 2018, 67(5): 253-263.
PANG Hui. An extended single particle model-based parameter identification scheme for lithium-ion cells[J]. Acta physica sinica, 2018, 67(5): 253-263.
- [8] AI W, WU B, MARTÍNEZ-PAÑEDA E. A coupled phase field formulation for modelling fatigue cracking in lithium-ion battery electrode particles[J]. Journal of power sources, 2022, 544: 231805.
- [9] 曹昕, 李棉刚, 侯宇程, 等. 锂离子电池均质化电化学模型的电极颗粒半径分布拓展[J]. 储能科学与技术, 2024, 13(10): 3622-3629.
CAO Xin, LI Miangang, HOU Yucheng, et al. Expansion of the homogeneous electrochemical model for lithium-ion batteries to incorporate electrode particle radius distribution[J]. Energy storage science and technology, 2024, 13(10): 3622-3629.
- [10] 杨发庆. 基于力热电耦合模型的锂离子电池安全分析[D]. 长春: 吉林大学, 2024.
YANG Faqing. Safety analysis of lithium-ion batteries based on mechanical-thermal-electric coupling model[D]. Changchun: Jilin University, 2024.
- [11] 赵帅. 锂离子电池内短路机理与诊断方法研究[D]. 长春: 吉林大学, 2022.
ZHAO Shuai. Study on the mechanism and diagnosis method of internal short circuit in lithium-ion power battery[D]. Changchun: Jilin University, 2022.

- [12] 赵英杰, 张闯, 刘素贞, 等. 基于电极等效电路模型的锂离子电池无析锂快充策略优化研究[J]. 电工技术学报, 2024, 39(18): 5868-5882.
ZHAO Yingjie, ZHANG Chuang, LIU Suzhen, et al. Optimization of fast charging strategy for lithium-ion batteries without deposition based on electrode equivalent circuit model[J]. Transactions of China electrotechnical society, 2024, 39(18): 5868-5882.
- [13] CHEN Z Y, XIONG R, TIAN J P, et al. Model-based fault diagnosis approach on external short circuit of lithium-ion battery used in electric vehicles[J]. Applied energy, 2016, 184: 365-374.
- [14] HANKINS K, KAMPHAUS E P, BALBUENA P B. Combined density functional theory/kinetic Monte Carlo investigation of surface morphology during cycling of Li-Cu electrodes[J]. Electrochimica acta, 2021, 397: 139272.
- [15] QIAN G Y, LI Y W, CHEN H B, et al. Revealing the aging process of solid electrolyte interphase on SiO_x anode[J]. Nature communications, 2023, 14(1): 6048.
- [16] YANG S C, WANG X, ZHOU S D, et al. Multi-scenario failure diagnosis for lithium-ion battery based on coupling PSO-SA-DBSCAN algorithm[J]. Journal of energy storage, 2024, 99(Part B): 113393.
- [17] ZHAO Hongqian, CHEN Zheng, SHU Xing, et al. Online surface temperature prediction and abnormal diagnosis of lithium-ion batteries based on hybrid neural network and fault threshold optimization[J]. Reliability engineering & system safety, 2024, 243: 109798.
- [18] ZHANG Huan, LAI Xin, ZHOU Long. A quantitative internal-short-circuit diagnosis method of lithium-ion batteries for float charging systems[J]. Journal of energy storage, 2024, 96: 112689.
- [19] SUN J L, CHEN S W, XING S Y, et al. A battery internal short circuit fault diagnosis method based on incremental capacity curves[J]. Journal of power sources, 2024, 602: 234381.

Research on fault diagnosis of lithium-ion batteries based on adaptive boosting of abnormal features

CAI Zeyang¹, ZHANG Liang², YANG Shichun¹, WANG Jinming³, YAN Xiaoyu⁴

(1. School of Transportation Science and Engineering, Beihang University, Beijing 100191, China;

2. Tianjin Fire Institute of M.E.M, Tianjin 300381, China;

3. Jiangsu Yonggui New Energy Technology Co., Ltd., Nanjing, Jiangsu 210038 China;

4. Research Institute of Aero-Engine, Beihang University, Beijing 100191, China)

Abstract: The battery management system (BMS) plays a pivotal role in ensuring the safety and stability of high-capacity lithium-ion batteries used in transportation systems. Early warning of battery safety issues, a core function of the BMS, traditionally relies on direct inspection of parameters such as voltage, current, and temperature. However, this approach suffers from short warning windows and a high rate of false alarms due to the subtle changes in macroscopic signals during the early stages of battery faults. To address these limitations, this study introduces the concept of safety entropy as a quantitative metric for assessing safety risks in power battery systems. Building upon this metric, a power battery system safety early warning algorithm has been developed, which integrates fault probability weights of battery system. Compared to conventional methods, this algorithm enables early quantitative risk assessment at the incipient stage of faults. Validation using historical accident data from new energy vehicles (NEVs) as well as NEV and charging station collaborative data demonstrates its effectiveness in risk identification, achieving a warning capability of 7 days in advance. The proposed safety entropy model and adaptive dynamic weighting mechanism provide a novel solution for the safety monitoring of high-capacity lithium-ion batteries in rail transit vehicles, significantly enhancing early warning capabilities.

Keywords: power battery; early warning of risks; fault diagnosis; new energy transportation