



基于增强分频模型的电池组微短路故障 定量诊断方法研究

唐 晶, 张士强, 周家旺, 杜 超, 朱文龙, 戴计生
(中车株洲电力机车研究所有限公司, 湖南 株洲 412001)

摘 要: 轨道交通新能源机车动力电池工况复杂且系统庞大, 诱发热失控的核心隐患——微短路(MSC)的微弱信号极易被掩盖, 传统方法难以克服干扰且精度不足, 因此实现高精度的诊断对保障安全运维至关重要。文章提出一种面向轨道交通动力电池微短路故障的增强型分频物理解耦定量诊断方法, 利用一阶RC与Warburg阻抗表征电池动态特性, 采用自适应扩展卡尔曼滤波(AEKF)将端电压实时解耦为能量流失、瞬态极化与扩散3个物理分量差异项, 并采用变分模态分解(VMD)与最小二乘法(RLS)联合算法实现微短路电阻的较高精度辨识, 最后结合容量-短路差异解耦逻辑建立五级风险预警体系, 实现微短路故障定量诊断。试验计算结果表明, 该方法对端电压的追踪精度极高(RMSE约为0.014 V), 对0.5 Ω 重度微短路工况辨识误差约为-8% (绝对误差为-0.04 Ω)。进一步结合某新能源机车高度非平稳工况数据进行验证, 端电压RMSE约为0.007 V, 能有效辨识并剔除由非短路因素引发的电压畸变干扰, 可为电池系统的安全运维提供可靠保障。

关键词: 轨道交通列车; 磷酸铁锂电池; 微短路(MSC); 定量辨识; 热失控预警

中图分类号: U267

文献标志码: A

文章编号: 1000-128X(2025)06-0157-08

0 引言

随着锂离子电池装机规模的持续扩大, 电池安全隐患日益凸显, 其中内短路(ISC)是电池热失控的关键共性诱因。内短路在演化初期通常表现为高阻值特征(几百欧姆量级), 学术界称之为微短路(MSC)^[1]。MSC虽然在短期内不至于触发热失控, 但其造成的持续能量损耗与局部温升极具隐蔽性, 若缺乏有效的在线监测与干预, 短路阻值可能随电化学反应发生急剧下降, 最终引发灾难性的安全事故。

锂电池微短路诊断是电池安全管理的核心难题, 实现方法可分为以下5种: ①基于时域统计及一致性的诊断方法^[2-7]: MSC触发的电压波动极微弱, 极易被单体容量差异、内阻等物理场噪声掩盖, 因此该方法在

复杂工况下的灵敏度与可靠性不足^[8]; ②硬件冗余及外部激励法: 包括充电剩余电量法^[9]、对称环形电路^[10]以及电化学阻抗谱(EIS)在线监测^[11], 此类方案依赖额外传感器或电路改造, 成本高昂, 制约了其工程应用; ③特征信号变换法: 以容量增量分析(ICA)^[12]为代表, 通过信号变换提取电化学特征, 该方法对数据质量及滤波算法要求严苛, 多局限于离线评估或故障电芯筛选; ④数据驱动方法: 包括长短期记忆网络^[13]、密度聚类^[14]等, 此类算法依赖海量训练样本, 物理可解释性缺失, 且对设备算力要求高, 难以适配低成本、高可靠的工业运维需求; ⑤基于物理模型的诊断方法: 具备深入揭示电池内部状态的演化机理、计算资源消耗适中且工程可追溯性强等优势, 但当前采用的方法存在产热不显著的MSC缺乏有效表征^[15]、未考虑内阻和容量差异因素^[16-17]等不足, 且应用范围多局限于试验

基金项目: 中国国家铁路集团有限公司科技研究开发计划项目(N2024J032-B(JB))

通信作者: 唐 晶, 男, 主要从事电池建模、状态估算与故障诊断方面的研究; E-mail: 18758072684@163.com

引用格式: 唐晶, 张士强, 周家旺, 等. 基于增强分频模型的电池组微短路故障定量诊断方法研究[J]. 机车电传动, 2025(6): 157-164. DOI:10.13890/j.issn.1000-128X.2025.06.018.

Citation: TANG Jing, ZHANG Shiqiang, ZHOU Jiawang, et al. Quantitative diagnostic method for micro-short circuit faults in battery packs based on an enhanced frequency-division model[J]. Electric drive for locomotives, 2025(6): 157-164. DOI:10.13890/j.issn.1000-128X.2025.06.018.

室环境下的小容量电池，尚未在具有大倍率激励、高度非平稳载荷特征的新能源机车大容量电芯上得到有效验证。

鉴于轨道交通动力电池系统在复杂动态载荷下表现出的高度非线性特征，本文旨在解决传统均值-差异模型（MDM）在强动态激励下难以有效剥离能量损失、难以消除极化电压与电化学扩散干扰，在低荷电状态（SOC）区间极易发生计算失准的固有问题^[18]，并提出一种微短路定量诊断架构。首先，构建基于 R-RC-W 结构的增强分频物理模型，通过引入一阶 RC 与 Warburg 阻抗来表征极化与扩散特性；其次，采用自适应扩展卡尔曼滤波（AEKF）将端电压偏差实时解耦；再次，通过 VMD-RLS 算法实现微短路电阻的高精度辨识，并基于 Warburg 阻抗构建容量-短路差异解耦逻辑，消除电池老化及容量一致性差异对微短路诊断的干扰，并建立五级风险预警体系；最后，基于某新能源车高度非平稳工况数据进行验证。

1 增强分频物理解耦模型

传统均值-差异模型中均值模型多采用单体电压的算术平均法或基于安时积分的库仑计数法，缺失对极化电压与电化学扩散等动态电压分量的实时表征，难以精确捕捉强动态载荷下的基准演化规律；差异模型仅计入 SOC 差异和内阻差异，未能剥离容量差异带来的长时漂移干扰，这导致该模型在低 SOC 区域易受电池电化学特性的剧烈非线性变化影响而发生辨识失准，同时也易受单体一致性演化的严重干扰。本文构建的增强分频物理模型实现了对传统 MDM 的优化，其主要包含两部分：改进的电池均值模型（I-CMM）及增强分频差异模型（E-CDM）。

建立的 I-CMM 电路模型及 E-CDM 电路模型如图 1 所示。




图1 I-CMM 及 E-CDM 等效电路模型

Fig. 1 Equivalent circuit models of I-CMM and E-CDM

根据基尔霍夫电压定律得到的 I-CMM 模型动态方程如下：

$$\left. \begin{aligned} U_{\text{mean},k} &= E_{\text{mean}}(A_{\text{SOC mean},k}) + I_k R_{0,\text{mean}} + U_{\text{p,mean},k} + U_{\text{w,mean},k} \\ U_{\text{p,mean},k} &= F_{\text{p,mean}} U_{\text{p,mean},k-1} + G_{\text{p,mean}} I_{k-1} \\ U_{\text{w,mean},k} &= U_{\text{w,mean},k-1} + R_{\text{w,mean}} \sqrt{\Delta t} \cdot I_k \end{aligned} \right\} \quad (1)$$

式中： $U_{\text{mean},k}$ 为平均端电压； $E_{\text{mean}}(A_{\text{SOC mean},k})$ 为均值开路电压； $I_k R_{0,\text{mean}}$ 为均值欧姆压降； $U_{\text{p,mean},k}$ 为中频极化电压，反映了中频尺度的电化学极化响应； $U_{\text{w,mean},k}$ 为低频扩散电压，表征由活性物质浓度梯度引起的电压偏移量； $U_{\text{p,mean},k-1}$ 为 $k-1$ 时刻的均值极化电压； I_k 和 I_{k-1} 分别为 k 时刻和 $k-1$ 时刻的电流； $U_{\text{w,mean},k-1}$ 为 $k-1$ 时刻的均值扩散电压； $R_{\text{w,mean}}$ 为电池组的均值扩散电阻，反映了电解质或电极材料中离子扩散受到的阻力程度； $F_{\text{p,mean}}$ 为状态转移系数， $F_{\text{p,mean}} = \exp(-\Delta t/\tau_{\text{p,mean}})$ ，其中， Δt 为采样周期， $\tau_{\text{p,mean}}$ 为电池组均值极化时间常数； $G_{\text{p,mean}}$ 为输入增益系数， $G_{\text{p,mean}} = R_{\text{p,mean}}[1 - \exp(-\Delta t/\tau_{\text{p,mean}})]$ ，其中， $R_{\text{p,mean}}$ 为均值极化电阻。

E-CDM 模型的核心在于将单体间的电压偏差分解为具有不同时间尺度特性的物理分量。定义电池组内第 i 个单体第 k 时刻与均值基准间的物理状态偏差向量 $\mathbf{x}_k^i$ 为

$$\mathbf{x}_k^i = [\Delta A_{\text{SOC},k}^i, \Delta U_{\text{p},k}^i, \Delta U_{\text{w},k}^i]^T \quad (2)$$

式中： $\Delta A_{\text{SOC},k}^i$ 、 $\Delta U_{\text{p},k}^i$ 和 $\Delta U_{\text{w},k}^i$ 分别为第 i 个电芯 k 时刻的 SOC 差异、极化电压差异和扩散电压差异，分别描述低频能量流失、中频电化学极化以及包含 Warburg 特性的低频扩散现象。

状态转移方程描述了状态向量从 $k-1$ 时刻到 k 时刻的离散演化过程，离散化系统状态空间方程可表述如下：

$$\left. \begin{aligned} \mathbf{x}_k^i &= \mathbf{A}_{k-1} \mathbf{x}_{k-1}^i + \mathbf{B}_{k-1} u_{k-1}^i + \mathbf{w}_{k-1}^i \\ \Delta U_k^i &= \mathbf{C}_k \mathbf{x}_k^i + \mathbf{D}_k u_k^i + v_k \end{aligned} \right\} \quad (3)$$

式中： ΔU_k^i 为第 i 个电芯 k 时刻的端电压差异； u_k^i 为第 i 个电芯 k 时刻的输入电流； $\mathbf{w}_{k-1}$ 为 $k-1$ 时刻的过程噪声矩阵； v_k 为第 k 时刻的测量噪声误差； $\mathbf{A}_{k-1}$ 和 $\mathbf{B}_{k-1}$ 为 $k-1$ 时刻的系数矩阵； $\mathbf{C}_k$ 和 $\mathbf{D}_k$ 为 k 时刻的系数矩阵。

$\mathbf{A}_{k-1}$ 、 $\mathbf{B}_{k-1}$ 、 $\mathbf{C}_k$ 和 $\mathbf{D}_k$ 的表达式为

$$\left. \begin{aligned} \mathbf{A}_{k-1} &= \frac{\partial f(\mathbf{x}_{k-1}^i, I_k)}{\partial \mathbf{x}_{k-1}^i} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{\Delta t}{\tau_p}} & 0 \\ 0 & 0 & 1 \end{bmatrix} \\ \mathbf{B}_{k-1} &= \begin{bmatrix} 0 \\ \Delta R_{\text{p}}^i \left(1 - e^{-\frac{\Delta t}{\tau_p}} \right) \\ \Delta R_{\text{w}}^i \sqrt{\Delta t} \end{bmatrix} \\ \mathbf{C}_k &= \frac{\partial h(\mathbf{x}_k^i, I_k)}{\partial \mathbf{x}_k^i} = \begin{bmatrix} \frac{\partial \Delta E}{\partial \Delta A_{\text{SOC}}} & 1 & 1 \end{bmatrix} \\ \mathbf{D}_k u_k^i &= I_k \Delta R_{0,k}^i + \Delta U_{\text{p},k}^i + \Delta U_{\text{w},k}^i \end{aligned} \right\} \quad (4)$$

式中: $\partial f(\mathbf{x}_{k-1}^i, I_k)$ 和 $\partial h(\mathbf{x}_k^i, I_k)$ 分别为 $k-1$ 时刻的状态方程和观测方程; I_k 为电流; τ_p 为极化时间常数; $I_k \Delta R_{0,k}^i$ 、 $\Delta U_{p,k}^i$ 和 $\Delta U_{w,k}^i$ 分别为第 i 个电芯 k 时刻的欧姆电压差异、极化电压差异和扩散电压差异; $\Delta R_{0,k}^i$ 、 ΔR_p^i 和 ΔR_w^i 分别为第 i 个电芯欧姆内阻差异、极化内阻差异和扩散内阻差异; ΔE 、 ΔA_{SOC} 分别为电压差异和 SOC 值差异。

将 E-CDM 模型参数矩阵与自适应扩展卡尔曼滤波 (AEKF) 相融合, 以实现复杂动态干扰下微弱漏电特征的实时剥离。通过新息序列动态调整测量噪声协方差矩阵 $\mathbf{R}$, 有效解决低 SOC 区域辨识易失准及 SOC-OCV 曲线斜率急剧增大导致的微小电压噪声被显著放大的问题。AEKF 解耦时参考文献[19]自适应解耦方法进行欧姆电压差异、极化电压差异和扩散电压差异解耦。

2 微短路定量辨识与风险分级预警策略

在完成 AEKF 多维特征解耦后, 提取出的 ΔA_{SOC} 信号仍然可能存在部分高频噪声或瞬态极化波动。因此, 本文通过变分模态分解 (VMD) 方法进行频域二次提纯, 并结合增广多变量递推最小二乘法 (RLS) 实现微短路电阻辨识。

2.1 基于 VMD 的低频漏电流趋势提取

VMD 用于将估计得到的 ΔA_{SOC}^i 自适应地分解为具有不同中心频率的模态分量, 对于 AEKF 输出的能量差异序列 ΔA_{SOC}^i , 通过构建约束变分问题进行分解, 实现方法为

$$\min_{\{u_m\}, \{v_m\}} \left\{ \sum_m \left\| \mathcal{H}_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_m(t) \right] e^{-jv_m t} \right\|_2^2 \right\} \quad (5)$$

式中: $u_m(t)$ 为分解得到的第 m 个模态分量; v_m 为对应的中心频率; $\mathcal{H}_t$ 为时域希尔伯特变换; $\delta(t)$ 为狄拉克函数。

在 VMD 分解结果中, 选取中心频率最低 (接近 0 Hz) 的模态分量作为纯净趋势项 $\Delta A_{\text{SOC trend}}^i$ 。

2.2 增广多变量 RLS 微短路电阻定量辨识

引入增广多变量 RLS 算法, 将 VMD 提取的趋势项 $\Delta A_{\text{SOC trend}}^i$ 与 AEKF 的观测残差 (新息序列) 共同纳入辨识框架。电量差异通过额定容量 C_N 与 SOC 差异趋势项 $\Delta A_{\text{SOC trend},k}^i$ 乘积获得, 公式为

$$\Delta Q_{\text{trend},k}^i = C_N \cdot \Delta A_{\text{SOC trend},k}^i \quad (6)$$

考虑漏电流与欧姆差异的增广观测方程为

$$\mathbf{Y}_k = \boldsymbol{\theta}_k \cdot \boldsymbol{\Phi}_k + \boldsymbol{\varepsilon}_k \quad (7)$$

式中: $\mathbf{Y}_k$ 为观测向量矩阵, $\mathbf{Y}_k = [\Delta Q_{\text{trend},k}^i, \mathbf{e}_k]^T$, 由 VMD 提纯后的电量累积差异 $\Delta Q_{\text{trend},k}^i$ 与 AEKF 预测新息序列 $\mathbf{e}_k$ 组成; $\boldsymbol{\theta}_k$ 为参数向量矩阵, $\boldsymbol{\theta}_k = [I_{\text{ISC},k}, \Delta R_{0,k}]^T$,

包含待辨识的漏电流 $I_{\text{ISC},k}$ 和内阻差异 $\Delta R_{0,k}$; $\boldsymbol{\Phi}_k$ 为包含时间累积项的矩阵, $\boldsymbol{\Phi}_k = [(t-t_0)\Delta t, I_t]^T$; $\boldsymbol{\varepsilon}_k$ 为噪声矩阵。

利用 RLS 算法实时修正参数向量 $\boldsymbol{\theta}_k$, 最小化加权误差平方和, 使漏电流 $I_{\text{ISC},k}$ 趋向于稳定值。最小二乘法包含增益矩阵 $\mathbf{L}_k$ 更新、参数向量 $\hat{\boldsymbol{\theta}}_k$ 估计及协方差矩阵 $\mathbf{P}_k$ 更新, 具体表示如下:

$$\left. \begin{aligned} \mathbf{L}_k &= \mathbf{P}_{k-1} \boldsymbol{\Phi}_k / (\lambda + \boldsymbol{\Phi}_k^T \mathbf{P}_{k-1} \boldsymbol{\Phi}_k) \\ \hat{\boldsymbol{\theta}}_k &= \hat{\boldsymbol{\theta}}_{k-1} + \mathbf{L}_k (\mathbf{Y}_k - \boldsymbol{\Phi}_k^T \hat{\boldsymbol{\theta}}_{k-1}) \\ \mathbf{P}_k &= \lambda^{-1} (\mathbf{P}_{k-1} - \mathbf{L}_k \boldsymbol{\Phi}_k^T \mathbf{P}_{k-1}) \end{aligned} \right\} \quad (8)$$

式中: $\hat{\boldsymbol{\theta}}_{k-1}$ 为上一时刻的估计值; $\mathbf{P}_{k-1}$ 为 $k-1$ 时刻的协方差矩阵; $\mathbf{L}_k$ 为 k 时刻的增益矩阵; λ 为遗忘因子, 取 $\lambda=0.98$ 。

上述参数向量 $\boldsymbol{\theta}_k$ 中第一个元素即为收敛后的漏电流。利用辨识出的漏电流 I_{ISC} 与均值模型提供的开路电压 $E_{\text{mean}}(A_{\text{SOC mean},k})$ 共同计算微短路电阻 $R_{\text{ISC},k}$, 公式为

$$R_{\text{ISC},k} = \frac{E_{\text{mean}}(A_{\text{SOC mean},k})}{I_{\text{ISC},k}} \quad (9)$$

2.3 基于物理项演化的容量-短路解耦方法及诊断分级体系

在电池组的实际运行中, 容量较小的电池与发生微短路的电池在单次放电过程中均表现为电压下降速度快于平均值, 这使得两者的特征极易被混淆。本文在已有解耦判据^[18]基础上增加基于 Warburg 阻抗的多维判据解耦即利用 Warburg 阻抗在静置阶段的松弛特性进行二次验证。由于电池容量的衰减通常伴随活性物质的损失, 在物理模型上表现为 Warburg 系数 ΔR_w^i 显著增大, 因此若 $\Delta A_{\text{SOC trend},k}^i$ 持续扩大且 ΔR_w^i 保持正常, 则判定为微短路故障; 若 $\Delta A_{\text{SOC trend},k}^i$ 随充放电倍率的变化剧烈波动且 ΔR_w^i 显著偏离均值, 则判定为单体老化导致的容量差异。

本方法依据 $R_{\text{ISC},k}$ 量级区间、演化收敛稳定性以及电芯在静置阶段的电量损耗特征, 参考已有分级策略^[1], 制定了五级风险分级决策体系, 具体分级标准及处置建议如表 1 所示。

3 试验验证及实车验证

3.1 微短路试验验证

3.1.1 HPPC 试验

采用 HPPC (hybrid pulse power characteristics) 混合动力脉冲试验获取该型号磷酸铁锂电池的 SOC-OCV 曲线, 并通过 5 次多项式进行最小二乘拟合, 得到 SOC-OCV 拟合关系式系数如表 2 所示, 拟合曲线的拟合优度 $R^2=0.9828$, 开路电压的均方根误差 RMSE 值为 0.0081 V。

表 1 微短路风险分级标准

Table 1 Classification standard for micro-short circuit hazards

微短路风险等级	判断准则	处置建议
一级（正常）	$I_{ISC,k} \approx 0$ 或 $R_{ISC,k} \geq 1\,000\,\Omega$ ，且物理分量无异常变化	维持常规监控：定期执行算法体检，记录各单体的一致性基准参数
二级（预警Ⅰ级）	$100\,\Omega \leq R_{ISC,k} < 1\,000\,\Omega$ ，且辨识阻值趋于稳定	强化趋势跟踪：标记为潜在风险单体，后台系统记录 $R_{ISC,k}$ 演化曲线
三级（预警Ⅱ级）	$10\,\Omega < R_{ISC,k} < 100\,\Omega$ ，且辨识阻值趋于稳定	运维计划干预：在最近的维保周期内执行受控放电或建议更换故障单体
四级（预警Ⅲ级）	$1\,\Omega < R_{ISC,k} \leq 10\,\Omega$ ，且静置段电量持续亏损	运行限制与降级：受控放电至安全电压，并尽快执行更换
五级（故障）	$R_{ISC,k} \leq 1\,\Omega$	强制切断高压回路：即刻检查电芯情况，更换电芯或更换整个电池组

表 2 SOC-OCV 拟合关系式系数

Table 2 Coefficients of SOC-OCV fitting

参数项目	P_1	P_2	P_3	P_4	P_5	P_6
参数值	13.018	-34.932	34.787	-15.850	3.370	3.005

3.1.2 微短路试验

试验电芯采用宁德时代已量产且已在轨道交通新能源机车多车型上搭载应用的磷酸铁锂电芯，电芯基本参数如表 3 所示。测试平台采用深圳新威（Neware）公司开发的高性能电池检测系统，试验环境为室内 25℃ 较恒温的环境。综合现有设备特点、测试安全性及成本等因素，试验方法参考业内普遍采用的外接不同阻值短路电阻的方式^[20]，以此模拟不同程度的电芯微短路故障。

表 3 试验电芯基本参数

Table 3 Basic parameters of experimental cell

电池类型	电极材料	正常电压/ V	标称容量/ (Ah)	充放电截 止电压/V	最大充 电倍率
磷酸铁锂	正极 Al/ 负极 Cu	3.22	230	3.65/2.50	1C

本文选取 0.5 Ω、1 Ω 及 5 Ω 共 3 个等级的外接短路电阻进行微短路试验，并与正常电芯（未外接电阻）形成对照，装置示意如图 2 所示。

考虑到新能源机车的主要工况为随机载荷下的放电工况，试验采用非线性、大跨度的动态电流激励，以模拟实际运用中的负荷跳变特征。微短路试验输入的电流激励以及测量获得的单体电压变化曲线如图 3 所示，试验时长为 19 595 s。试验数据表明，电压偏离程度与外接电阻阻值呈显著的负相关关系：外接电阻越小（即微短路程度越严重），电压曲线的下行分叉越严重，且该偏差在放电末期（低 SOC 区域）达到峰值。从电化学反应的本质分析，外接电阻作为寄生负载持续消耗电芯能量；阻值越小则对应的微短路电流 I_{ISC} 越大，单位时间内的能量损耗越大，单体 SOC 的跌落越快，具体表现为端电压更早、更快地偏离了正常工作范围。

在采用 5 Ω 电阻模拟短路工况的条件下，模型预测




图 2 微短路试验测试装置

Fig. 2 Micro-short circuit experimental setup

电压与试验实测电压在放电全过程中的演化对比以及 SOC 值为 20% 关键非线性区域的局部放大特征如图 4 所示。试验结果表明，采用本文方法构建的模型对电池在动态载荷下的端电压具备较好的追随特性，各阶段模型输出值与试验测量值重合度较高，端电压均方根误差 RMSE 为 0.014 V，平均相对误差 MRE 为 0.195 4%，最大绝对误差 MAE 为 0.056 V，表明该模型能在端电压残差中准确剥离出微弱的漏电特征，在 SOC 较低处也能避免微短路电阻计算的发散。

5 Ω 电阻模拟短路工况时模型输出的预测 SOC 曲线（红色虚线）与试验测量的参考 SOC 曲线（黑色实线）对比如图 5 所示。图 5 中两条曲线在全放电周期内重合度较高，SOC 值均方根误差 RMSE 为 0.008，平均相对误差 MRE 为 1.74%，最大绝对误差 MAE 为 0.017。结果表明，即使在复杂的载荷跳变及大电流放电区间，模型依然表现出优异的动态实时跟踪能力，这证明了 E-CDM 模型引入容量差异及 Warburg 扩散项后，能够




图3 试验电流及单体电压曲线

Fig. 3 Experimental current and cell voltage curves




图4 模型输出端电压与试验测量端电压对比(5 Ω)

Fig. 4 Comparison of modeled and measured terminal voltage (5 Ω)

有效捕捉电芯真实的能量状态变化。

不同外接电阻条件下的估计值与参考值对比情况以及稳态区间的局部放大细节如图6所示。所有组别的辨识电阻值 R_{ISC} 均从初始高阻抗点开始即呈现出显著的




图5 模型输出SOC值与试验测量SOC值对比

Fig. 5 Comparison of modeled and measured SOC

指数级陡降趋势, 表明AEKF-VMD-RLS的联合算法能够快速锁定漏电流特征。在稳定收敛区间段内, 外接 $0.5\ \Omega$ 、 $1\ \Omega$ 及 $5\ \Omega$ 短路电阻的估计值分别收敛到 $0.46\ \Omega$ 、 $1.22\ \Omega$ 及 $6.63\ \Omega$, 绝对误差分别为 $-0.04\ \Omega$ 、 $0.22\ \Omega$ 及 $1.63\ \Omega$, 结果表明, 尽管随着外接电阻阻值的增大辨识误差有所上升, 但整体数值仍能准确反映故障严重程度。由于算法存在高斯白噪声且试验台架的物理连接在测量环路中不可避免地引入了等效接触电阻或寄生阻抗等, 正常电芯(黑色)的辨识电阻最终收敛于 $1\ 340\ \Omega$ 附近, 而非理想情况下的无穷大。根据前述风险分级策略, 该值显著高于 $1\ 000\ \Omega$ 的安全阈值, 系统将其判定为无短路风险的正常状态, 试验验证了算




图6 不同外接电阻辨识值与参考值对比曲线图

Fig. 6 Comparison curves of external-resistor identification results and reference values

法在边界条件下的鲁棒性。

3.2 实车数据验证

鉴于暂未收集到现场微短路故障数据,为进一步验证 AEKF-VMD-RLS 联合算法在复杂工程环境下的鲁棒性与适应性,本研究采用某新能源机车于 2024 年 5 月份报出的“单体压差过大”故障历史数据进行交叉验证。新能源机车实车运行数据(#2 电芯)的模型输出端电压/SOC 值与试验测量端电压/SOC 值对比曲线图及其局部放大特征如图 7 所示。试验结果表明,尽管新能源机车运行电流具有频繁剧烈波动与长时平稳交替的高度非平稳特征,该增强型分频差异模型仍表现出优异的全局追随性能。尤其在放电电荷段及长时静置段,预测电压与试验测量值高度重合。端电压均方根误差 RMSE 为 0.007 V,平均相对误差 MRE 为 0.130 3%,最大绝对误差 MAE 为 0.041 V; SOC 值 A_{SOC} 均方根误差 RMSE 为 0.006,平均相对误差 MRE 为 0.684%,最大绝对误差 MAE 为 0.010。在充电阶段(电压上升区),预测曲线与实测曲线出现明显的正向偏差(或系统性偏移),模型敏感度有所下降,从电化学机制分析,这主要是由于模型对充电过程中的非线性极化效应刻画尚不够充分。本研究在算法设计中通过精度的适度让步来换取计算的高效性:虽然通过增加等效电路模型阶数(如采用二阶 RC)可进一步缩小该偏差,但会显著提升在线计算的复杂度和矩阵求逆的计算负担,且可能影响模型在高动态工况下的收敛稳定性。






图 7 模型输出端电压/ A_{SOC} 与试验测量端电压/ A_{SOC} 对比曲线图(#2 电芯)

Fig. 7 Comparison curves of modeled terminal voltage/ A_{SOC} and measured terminal voltage/ A_{SOC} (cell 2)

图 8 为该模型对#2、#5 和#9 电芯微短路电阻的辨识曲线,试验结果显示,尽管这 3 个单体在实测数据中表现出显著的端电压分层与压差波动,但经过算法的物理场解耦与增广 RLS 辨识,其计算结果在稳态区间表现出极高的阻抗特性,3 个电芯最小辨识阻值为 2 000 Ω 左右,最大辨识阻值为 $1.38 \times 10^7 \Omega$,根据微短路风险分级,所有辨识阻值均远超 1 000 Ω 的一级(正常)安全阈值,因此诊断得出 3 个电芯均未出现微短路故障,证明了该模型在面对“非短路电压畸变”时,依然具备精准的物理本质辨识能力。



(a) #2、#5 和#9 电芯辨识阻值曲线(全过程)



(b) #5 和#9 电芯辨识阻值局部曲线(7 837~16 218 s)

图 8 #2、#5 和#9 电芯微短路阻值辨识曲线图

Fig. 8 Curves of micro-short circuit resistance identification results for cells 2, 5 and 9

4 结论

针对轨道交通新能源机车动力电池系统在强动态载荷、大功率激励下微短路故障特征难以提取的痛点,本文提出并验证了一种基于增强型分频物理解耦模型与自适应增广辨识算法的定量诊断方法及分级策略,主要研究结论如下:

①通过构建引入一阶 RC 与 Warburg 阻抗的增强型分频差异模型(E-CDM),实现将端电压偏差实时解耦为能量流失、中频极化及低频电化学扩散 3 个维度的物理分量。

②自适应扩展卡尔曼滤波(AEKF)利用新息序列动态调整测量噪声协方差 R_k ,有效抑制了低 A_{SOC} 区域 dE/dA_{SOC} 斜率剧增导致的计算失准;在基于 ΔA_{SOC} 演化

速率的判别方法基础上增加基于 Warburg 阻抗的辅助判别, 消除了老化干扰对诊断结果的影响。

③实验室工况下端电压 RMSE 为 0.014 V, 实车工况下 RMSE 进一步优化至 0.007 V, 表现出较好的全局追随特性; 增广多变量 RLS 算法对重度短路 ($0.5\ \Omega$) 下的电阻估计误差约为 12% ($0.06\ \Omega$), 实现了不同严重程度短路电芯及正常电芯的有效区分。

本文提出的方法为阻断电池从微短路故障向热失控不可逆阶段演化的链路提供了可靠的预警依据, 在轨道交通动力电池系统的精细化监测与主动安全运维方面具有显著的工程应用价值。

参考文献:

- [1] 张明轩. 汽车动力电池系统内短路问题研究[D]. 北京: 清华大学, 2018.
ZHANG Mingxuan. Research on the internal short circuit problem of the vehicle power battery system[D]. Beijing: Tsinghua University, 2018.
- [2] 李纪伟, 刘睿涵, 吕桃林, 等. 基于局部离群点检测和标准差方法的锂离子电池组早期故障诊断[J]. 储能科学与技术, 2023, 12(9): 2917-2926.
LI Jiwei, LIU Ruihan, LYU Taolin, et al. Early fault diagnosis of lithium-ion battery packs based on improved local outlier detection and standard deviation method[J]. Energy storage science and technology, 2023, 12(9): 2917-2926.
- [3] ASAKURA J, NAKASHIMA T, NAKATSUJI T, et al. Battery internal short-circuit detection apparatus and method, and battery pack: US-8334699-B2[P]. 2012-12-18.
- [4] KEATES A W, OTANI N, NGUYEN D J, et al. Short circuit detection for batteries: US7795843[P]. 2010-09-14.
- [5] 张香林, 李侨, 肖息, 等. 锂电池微短路机理及其在线检测[J]. 机械工程与自动化, 2024(4): 16-18.
ZHANG Xianglin, LI Qiao, XIAO Xi, et al. Mechanism and online detection of micro-short circuit in lithium batteries[J]. Mechanical engineering & automation, 2024(4): 16-18.
- [6] 龚辉, 戴海峰, 乔冬冬. 基于弛豫电压的内短路诊断方法[J]. 电池, 2022, 52(5): 488-491.
GONG Hui, DAI Haifeng, QIAO Dongdong. Diagnosis method of internal short circuit based on relaxation voltage[J]. Battery bimonthly, 2022, 52(5): 488-491.
- [7] 李晨, 姜兵, 夏伟栋, 等. 适用于串联电池包的短路故障诊断方法[J]. 电源技术, 2021, 45(8): 1008-1011.
LI Chen, JIANG Bing, XIA Weidong, et al. Short circuit fault diagnosis method for series connected battery pack[J]. Chinese journal of power sources, 2021, 45(8): 1008-1011.
- [8] FENG X N, WENG C H, OUYANG M G, et al. Online internal short circuit detection for a large format lithium ion battery[J]. Applied energy, 2016, 161: 168-180.
- [9] 郑岳久. 车用锂离子动力电池组的一致性研究[D]. 北京: 清华大学, 2014.
ZHENG Yuejiu. Study on cell variations of lithium ion power battery packs in electric vehicles[D]. Beijing: Tsinghua University, 2014.
- [10] ZHANG M X, OUYANG M G, LU L G, et al. Battery internal short circuit detection[J]. ECS transactions, 2017, 77(11): 217-223.
- [11] 张闯, 王泽山, 刘素贞, 等. 基于电化学阻抗谱的锂离子电池过放电诱发内短路的检测方法[J]. 电工技术学报, 2023, 38(23): 6279-6291.
ZHANG Chuang, WANG Zeshan, LIU Suzhen, et al. Detection method of overdischarge-induced internal short circuit in lithium-ion batteries based on electrochemical impedance spectroscopy[J]. Transactions of China electrotechnical society, 2023, 38(23): 6279-6291.
- [12] 江露露. 锂离子电池包内短路故障诊断与热失控安全预警研究[D]. 重庆: 重庆大学, 2022.
JIANG Lulu. Study on internal short circuit fault diagnosis and thermal runaway safety warning of lithium-ion battery packs[D]. Chongqing: Chongqing University, 2022.
- [13] LI D, ZHANG Z S, LIU P, et al. Battery fault diagnosis for electric vehicles based on voltage abnormality by combining the long short-term memory neural network and the equivalent circuit model[J]. IEEE transactions on power electronics, 2021, 36(2): 1303-1315.
- [14] LI D, ZHANG Z S, LIU P, et al. DBSCAN-based thermal runaway diagnosis of battery systems for electric vehicles[J]. Energies, 2019, 12(15): 2977.
- [15] 冯旭宁. 车用锂离子动力电池热失控诱发与扩展机理、建模与防控[D]. 北京: 清华大学, 2016.
FENG Xuning. Thermal runaway initiation and propagation of lithium-ion traction battery for electric vehicle: test, modeling and prevention[D]. Beijing: Tsinghua University, 2016.
- [16] DAI H F, WEI X Z, SUN Z C, et al. Online cell SOC estimation of Li-ion battery packs using a dual time-scale Kalman filtering for EV applications[J]. Applied energy, 2012, 95: 227-237.
- [17] 张莉, 高兴奇, 张健豪. 基于平均-差异模型的电池组短路电流估计[J]. 汽车工程, 2021, 43(11): 1702-1709.
ZHANG Li, GAO Xingqi, ZHANG Jianhao. Short-circuit current estimation of battery pack based on average-difference model[J]. Automotive engineering, 2021, 43(11): 1702-1709.
- [18] GAO W K, ZHENG Y J, OUYANG M G, et al. Micro-short-circuit diagnosis for series-connected lithium-ion battery packs using mean-difference model[J]. IEEE transactions on industrial electronics, 2019, 66(3): 2132-2142.
- [19] HE H W, XIONG R, ZHANG X W, et al. State-of-charge estimation of the lithium-ion battery using an adaptive extended Kalman filter based on an improved Thevenin model[J]. IEEE transactions on vehicular technology, 2011, 60(4): 1688-1698.

- 1461-1469.
- [20] 杨瑞鑫, 熊瑞, 孙逢春. 锂离子动力电池外部短路测试平台开发与试验分析[J]. 电气制造, 2021, 16(1): 103-118.
- YANG Ruixin, XIONG Rui, SUN Fengchun. Experimental platform development and characteristics analysis of external short circuit in lithium-ion batteries[J]. Electrical manufacturing, 2021, 016(1): 103-118.
- [21] 朱景哲, 张希, 高一钊, 等. 数据驱动的锂离子电池智能故障诊断算法[J]. 电池, 2022, 52(4): 401-405. DOI: 10.19535/j.1001-1579.2022.04.010.
- ZHU Jingzhe, ZHANG Xi, GAO Yizhao, et al. Data driven intelligent fault diagnosis algorithm for Li-ion battery[J]. Battery bimonthly, 2022, 52(4): 401-405. DOI: 10.19535/j.1001-1579.2022.04.010.

Quantitative diagnostic method for micro-short circuit faults in battery packs based on an enhanced frequency-division model

TANG Jing, ZHANG Shiqiang, ZHOU Jiawang, DU Chao, ZHU Wenlong, DAI Jisheng

(CRRC Zhuzhou Institute Co., Ltd., Zhuzhou, Hunan 412001, China)

Abstract: Power batteries in new-energy rail transit locomotives form large-scale systems operating under complex conditions, where the weak signs of micro-short circuits (MSC)—a core hidden hazard that can trigger thermal runaway—are easily obscured. Since traditional methods suffer from interference and limited accuracy, high-precision, refined diagnosis is crucial for safe operation and maintenance. This paper proposes an enhanced frequency-division physical-decoupling method for quantitative diagnostic of MSC faults in power batteries for rail transit applications. A first-order resistor-capacitor (RC) and Warburg impedance were utilized to characterize dynamic battery characteristics. An adaptive extended Kalman filter (AEKF) was employed to decouple the terminal voltage in real time into three physical components for diagnostic differentiation: energy loss, transient polarization, and diffusion. Furthermore, a combined algorithm of variational mode decomposition (VMD) and recursive least squares (RLS) was adopted to achieve relatively high-precision identification of MSC resistance. By integrating a decoupling logic for capacity and short-circuit differences, a five-level risk warning system for quantitative diagnosis of MSC faults was established ultimately. Experimental and computational results demonstrate that the proposed method exhibits extremely high terminal-voltage tracking precision (RMSE of approximately 0.014 V). Under severe MSC conditions ($0.5\ \Omega$), the identification error is about -8% (absolute error of $-0.04\ \Omega$). Further validation using data from a new-energy locomotive operating in highly unstable conditions indicates a terminal-voltage RMSE of approximately 0.007 V. The method effectively identifies and eliminates voltage-distortion interference from non-short-circuit factors, providing a reliable guarantee for safe operation and maintenance of battery systems.

Keywords: rail transit train; lithium iron phosphate (LFP) battery; micro-short circuit (MSC); quantitative identification; thermal runaway warning