

基于局部均值分解与局部离群因子动力电池故障诊断

胡杰^{1,2,3}, 贾超明^{1,2,3}, 程雅钰^{1,2,3}, 余海^{1,2,3}

1. 武汉理工大学 现代汽车零部件技术湖北省重点实验室, 武汉 430070;
2. 武汉理工大学 汽车零部件技术湖北省协同创新中心, 武汉 430070;
3. 新能源与智能网联汽车湖北省工程技术研究中心, 武汉 430070)

摘要: 动力电池故障诊断是保证电动汽车正常运行的关键。提出一种基于局部均值分解和局部离群因子的动力电池故障诊断方法, 用于电池组故障识别与定位。通过局部均值分解对电压信号预处理, 并根据相关系数高低重构电压信号。进一步提取重构信号的峭度因子作为故障特征输入到局部离群因子算法中, 根据局部离群因子算法自适应阈值输出故障电池。采用实车数据验证了所提方法能有效、准确地检测出故障, 具有较好的可靠性与鲁棒性。

关键词: 局部均值分解; 峭度; 故障诊断; 局部离群因子; 动力电池

中图分类号: U469.72 文献标志码: A DOI: 10.3969/j.issn.2095-1469.2024.03.10

Fault Diagnosis of Power Batteries Based on Local Mean Decomposition and Local Outlier Factor

HU Jie^{1, 2, 3}, JIA Chaoming^{1, 2, 3}, CHENG Yayu^{1, 2, 3}, YU Hai^{1, 2, 3}

1. Hubei Key Laboratory of Modern Auto Parts Technology, Wuhan University of Technology, Wuhan 430070, China;
2. Auto Parts Technology Hubei Collaborative Innovation Center, Wuhan University of Technology, Wuhan 430070, China;
3. Hubei Technology Research Center of New Energy and Intelligent Connected Vehicle Engineering, Wuhan 430070, China)

Abstract: The diagnosis of power battery faults is crucial for the normal operation of electric vehicles. In response, this paper proposes a power battery fault diagnosis method using local mean decomposition and the local outlier factor, aimed at fault recognition and localization within battery packs. Firstly, the voltage signal is preprocessed through local mean decomposition, followed by the reconstruction of the voltage signal according to the correlation coefficient. Furthermore, the kurtosis factor of the reconstructed signal is extracted as the fault feature input to the local outlier factor algorithm, which then identifies the faulty battery based on an adaptive threshold. Finally, the proposed method is validated on a real vehicle, effectively and accurately detecting faults while demonstrating the reliability and robustness of the method.

Keywords: local mean decomposition; kurtosis; fault diagnosis; local outlier factor; power battery

收稿日期: 2023-12-12 改稿日期: 2024-01-21

基金项目: 广西科技重大专项(23062062)

参考文献引用格式:

胡杰, 贾超明, 程雅钰, 等. 基于局部均值分解与局部离群因子动力电池故障诊断[J]. 汽车工程学报, 2024, 14(3): 422-432.

HU Jie, JIA Chaoming, CHENG Yayu, et al. Fault Diagnosis of Power Batteries Based on Local Mean Decomposition and Local Outlier Factor[J]. Chinese Journal of Automotive Engineering, 2024, 14(3): 422-432. (in Chinese)



锂离子电池因使用寿命长, 能量密度高等优势被广泛应用于电动汽车储能系统。然而动力电池会经常出现故障, 严重情况下甚至导致车辆烧毁。因此, 对动力电池系统故障诊断的研究具有重要的现实意义和应用价值。对动力电池进行故障诊断, 有利于对故障电池进行维护, 提高动力电池的安全性和使用寿命。

目前, 电池故障诊断的研究方向主要是基于信号处理和数据驱动的动力电池故障诊断。基于信号处理的方法主要是在时域或频域分析信号的波形和幅度等, 通常采用电压、电流和温度等信号。造成电动汽车动力电池故障的主要因素包括温度异常、过充、过放、欠压、过压、均衡失效、充放电电流异常、自放电、内阻异常和电池衰老以及各单体电池电压异常, 这些故障情形都能通过电压表现出来, 因为每种锂电池的电压都有其合理的范围。例如, 三元锂电池电压在2.5~4.2 V之间(最高充电电压为4.2 V, 最低放电电压为2.5 V, 标称电压3.7 V), 磷酸铁锂电池电压在2.0~3.65 V之间(最高充电电压为3.65 V, 最低放电电压为2 V, 其中标称电压3.2 V)。刘鹏等^[1]构建了基于单体电池电压数据的故障诊断模型, 提出了一种基于FFT和异常系数评估的故障诊断方法。该方法适用于诊断单一类型的故障, 不适用于诊断多种类型的故障。WANG Zhenpo等^[2]提出了一种基于信息熵和z分数的电压异常诊断方法, 有效检测电压异常, 预测电压故障发生的时间和位置, 初步实现了热失控预警。该方法可以有效地检测和定位电池故障, 但随着诊断精度的提高, 模型计算量会大幅增加。CHANG Chun等^[3]提出一种基于变分模态分解和无量纲特征参数的电压异常诊断方法, 采用局部离群因子检测异常电池。该方法在分解电压信号前需确定模态分量个数, 难以适应各种车型的故障诊断。

赵士博等^[4]提出一种基于模糊逻辑和神经网络的诊断方法, 模糊逻辑描述故障症状, 神经网络学习电池故障信息, 实现了对电池故障的准确诊断。古昂等^[5]设计了一种基于RBF神经网络的电池故障诊断系统, 能准确诊断电池故障的类型和级别。HONG Jichao等^[6]将LSTM用于电池系统电压状态异常诊断。DENG Fuxiang等^[7]提出了一种基

于多分类支持向量机(SVM)的电池故障诊断方法。QIU Yan等^[8]提出了一种基于非线性自回归外生神经网络和箱线图的诊断方法, NARX神经网络根据收集到的电压和电流数据预测未来的电池电压, 然后采用箱线图根据预测的电压诊断电池故障。基于数据驱动的故障诊断方法中, 不同的模型具有不同的故障识别性能。一个模型可能只对某一种故障类型具有较好的诊断性能, 且单一的神经网络模型很难以较高的准确率诊断所有的故障类型, 并且数据驱动故障诊断需要大量故障数据进行模型训练。

基于数据的数据驱动故障诊断方法比较容易实现, 但没有考虑对数据进行预处理的阶段, 提取的特征参数大多是电池信号线性相关的参数, 然而电池信号是非线性的, 导致诊断精度低。因此, 本文提出了一种基于局部均值分解(Local Mean Decomposition, LMD)与重构和局部离群因子(Local Outlier Factor, LOF)算法的电池故障诊断方法。通过对原始信号进行分解得到各个分量, 去除噪声干扰, 重构后的信号携带更多的异常信息。提取重构信号峭度因子作为特征参数, 减少了计算量。最后采用局部离群因子算法对故障电池进行检测。故障诊断流程如图1所示。

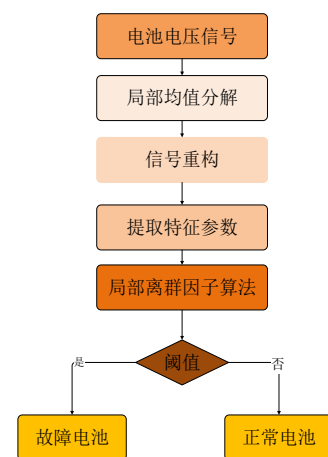


图1 故障诊断流程

1 LMD算法原理

单体电池电压信号是典型的时间序列信号, 电压信号通常被认为由静态部分和动态部分组成。为

为了准确提取原始信号的特征, 需要通过合适的方法将原始信号分解。傅里叶变换是一种经典的信号处理方法, 对于平稳信号能有效去除噪声, 但是对于非线性信号处理效果不佳。因此, 提出的小波变换能有效处理随机、非平稳信号, 但需要在降噪处理过程中进行人为干预, 如选择小波基函数、小波分解层数、降噪阈值等, 对于参数选择不同, 小波变换的降噪效果也会出现偏差。因此, 小波变换能弥补傅里叶变换的一些缺陷, 但仍然受到一定限制。在此基础上提出了经验模态分解 (Empirical Mode Decomposition, EMD), EMD 作为一种自适应的信号分析方法, 在无需人为选择基函数的条件下, 能将信号自适应分解为一系列不同尺度的固有模态函数 (Intrinsic Mode Functions, IMF), 并通过选择特定的固有模态函数, 实现特定的低通、带通、高通滤波。但 EMD 在分解过程中会产生模态混叠问题, 即同一个 IMF 分量当中出现不同频率或尺度的信号, 或同一尺度或频率的信号被自行分解到多个不同的 IMF 分量中。虽然集成经验模态分解 (Ensemble Empirical Mode Decomposition, EEMD) 通过多次对信号加入不同的高斯噪声, 再进行 EMD 分解, 将多个结果求平均获得更加可靠的 IMF, 但添加高斯噪声会增加计算量, 并且添加噪声幅值和迭代次数不恰当时会产生更多的伪 IMF 分量, 造成较大的结果误差 [9]。

LMD 方法是一种新的时频分析方法, 其方式是将复杂多分量的原始信号分解成若干个 PF 分量的乘积和残余分量的和, 每一个 PF 分量的本质是调频调幅信号的乘积。因此, 对于给定的任意的一个原始信号 $x(t)$, 都可以通过 LMD 分解转换为:

$$x(t) = \sum_{p=1}^k \text{PF}_p(t) + u_k(t) \quad (1)$$

式中: $x(t)$ 为单体电池电压; $\text{PF}_p(t)$ 为分解出来 k 个单分量信号; $u_k(t)$ 为分解后的残差分量。分解过程如下 [10]。

1) 构造局部均值函数。找到信号 $x(t)$ 的局部极值点 n_i , 并求出相邻两个极值点的平均值 m_i , 即:

$$m_i = \frac{n_i + n_{i+1}}{2} \quad (2)$$

再将求得的 m_i 用折线连接起来, 并通过滑动平均的方式对其进行平滑处理, 得到局部均值函数 $m_{11}(t)$ 。

2) 构造包络估计值函数。求出相邻两个极值点的包络估计值 a_i , 有:

$$a_i = \left| \frac{n_i - n_{i+1}}{2} \right| \quad (3)$$

将所有求得的 a_i 用折线连接起来, 同样采取滑动平均的方式得到包络估计函数 $a_{11}(t)$ 。

3) 解调:

$$s_{11}(t) = \frac{h_{11}(t)}{a_{11}(t)} \quad (4)$$

式中: $h_{11}(t) = x(t) - m_{11}(t)$ 。

4) 对解调得到的 $s_{11}(t)$ 进行判定。取 $s_{11}(t)$ 的包络估计函数 $a_{12}(t)$, 若 $a_{12}(t) = 1$, 则得到的 $s_{11}(t)$ 为纯调频信号, 若 $a_{12}(t) \neq 1$, 则重复上述步骤进行 n 次迭代直到 $s_{1n}(t)$ 为纯调频信号, 因此, 有:

$$\begin{cases} h_{11}(t) = x(t) - m_{11}(t), \\ h_{12}(t) = s_{11}(t) - m_{12}(t), \\ \dots \\ h_{1n}(t) = s_{1(n-1)}(t) - m_{1n}(t). \end{cases} \quad (5)$$

其中:

$$\begin{cases} s_{11}(t) = \frac{h_{11}(t)}{a_{11}(t)}, \\ s_{12}(t) = \frac{h_{12}(t)}{a_{12}(t)}, \\ \dots \\ s_{1n}(t) = \frac{h_{1n}(t)}{a_{1n}(t)}. \end{cases} \quad (6)$$

迭代停止条件为:

$$\lim_{x \rightarrow t} a_{1n}(t) = 1。$$

5) 用瞬时幅值 $a_{11}(t)$ 乘以纯调频信号 $s_{1n}(t)$ 得到第一个 PF 分量:

$$\text{PF}_1(t) = a_1(t)s_{1n}(t) \quad (7)$$

式中: $a_1(t) = \prod_{j=1}^n a_{1j}(t)$, 此时 $a_1(t)$ 和 $s_{1n}(t)$ 分别为第 1 个 PF 分量的瞬时幅值和瞬时频率。

6) 将 PF 分量从原始信号 $x(t)$ 和 $u_{1r}(t)$ 作为新

的原始信号，重复步骤1~5，循环 k 次，直到 $u_k(t)$ 为单调函数：

$$u_k(t) = x(t) - \sum_{p=1}^k \text{PF}_p(t)。 \quad (8)$$

2 故障诊断方法

2.1 LMD分解与重构

利用局部均值分解算法将单体电池电压信号分解为具有真实物理意义的乘积函数(PF)，每个PF分量都是一个纯调频信号和包络信号的乘积，且每个PF分量的瞬时频率具有实际物理意义，并由此得到能清晰准确地反映信号能量在空间各尺度上分布规律的时频分布，有利于更加细致地对信号特征进行分析。现有的方法存在参数选择困难等问题，

LMD分解可以更好地分解电压信号，重构后电压信号可以很好地去除噪声的影响。

本文所采用的数据均为单体电池电压信号，各个电池的复杂程度不同，可能分解后得到的PF分量个数也不同。先通过LMD将各个单体电池的原始电压信号分解为不同的分量，图2为LMD分解的PF1-PF6分量图，分解后的分量数量均为6个。前3个分量在发生故障前后出现了明显的的不一致。后两个分量在发生故障前的一段时间开始出现异常的紊乱。很明显后两个PF分量的不一致性远高于电池原始电压信号的不一致性。此时的PF分量包含更多的异常信息，有利于提前发现微小故障，进行故障预警。

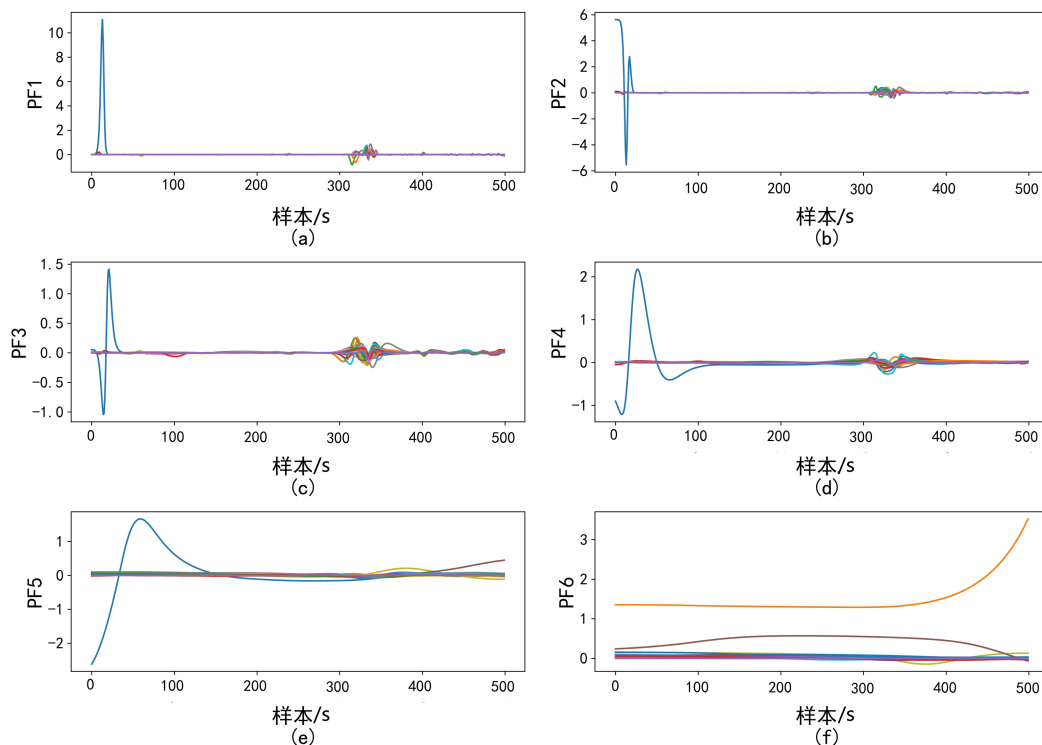


图2 LMD分量图

对于非线性单体电池电压信号，LMD可以很好地进行信号分解处理。将原始单体电池电压信号进行LMD分解。而模态分量重构是将分解后的分量重构为新的信号，作为分析的基础，是信号预处理的关键步骤。大多数研究人员将分量分为高频分量与低频分量，仅仅使用高频分量与低频分量进行

信号重构，会使重构后的信号失去部分异常信息。由于LMD算法本身的完备性，可以根据分量的自相关重构的原理得到原始信号。因此，先去除相关系数最大的PF分量，从而剔除高频噪声干扰，进一步提高信噪比。然后取剩余PF分量用以重构信号^[11]。具体重构步骤为：

- 1) 计算所有 PF 分量与原始信号的相关系数;
- 2) 去除相关系数最大的 PF 分量;
- 3) 取剩余 PF 分量叠加得到重构信号。

图 3 为 1 号电池的 PF 分量与原始电压信号的相关系数热力图, 对于该电池, 去除 PF3, 然后叠加剩余的 PF 分量得到重构信号。




图 3 分量与原始信号热力图

叠加降噪后的分量 PF, 得到重构信号, 图 4a 为分解前的原始电压信号, b 为重构后的电池电压信号。对比重构前后的图像, 原始电压信号的不一致性非常微弱, 但是经过重构之后的特征, 在发生故障时刻后的不一致性非常明显, 证明 LMD 分解后重构的数据特征包含了大部分的故障信息。0 号电池和 85 号电池在样本点为 0 的时刻, 其经过重构后的信号与其他电池产生了明显的差异, 0 号电池的异常持续到第 375 个样本时刻结束, 同时 85 号电池的异常持续到第 584 个样本时刻结束。在第 839 个样本时刻 33 号电池出现异常, 并持续到结束时的采样时刻。与原始信号相比, 重构信号中与故障相关的特性更加明显, 其他的噪声与干扰被抑制。并且在故障发生之前就已经出现了数据的波动, 这有利于提前发现微小的电池内部故障, 提前预警。因此, 该方法能有效提取故障信息, 并放大故障信息, 为后文提取故障特征参数提供基础。

2.2 故障特征提取

峭度反映了振动信号的冲击特性, 峭度对于冲击比较敏感, 因此, 可以用来确定电压序列的分布




图 4 原始信号与重构信号对比

模式与稀疏性。重构模态分量后, 提取并计算电池单体的峭度因子。原始信号包含的故障信息越高或越快, 峭度值越大。峭度因子计算式为:

$$S(t) = \sum_{i=1}^n A e^{-\zeta \left[t \cdot \frac{g_i(t)}{f} \right]^2} \sin(2\pi f_0 t) + n(t) \quad (9)$$

式中: A 为振幅; ζ 为阻尼比; f 为特征频率; f_0 为系统的固有频率; $n(t)$ 为噪声。

在故障特征参数中, 脉冲因子、偏度系数与峭度因子被广泛应用于故障诊断中, 本文采取峭度因子作为故障特征参数。峭度因子计算过程更加简便, 在线故障诊断更容易实现, 后文详细阐述了采用峭度因子的原因。相对于多参数特征序列, 单参数特征在滑动窗口内更能指示电池信号趋势, 并能提高 LOF 算法在故障诊断领域的鲁棒性。

峭度因子可以反映样本数据中是否存在异常冲击。根据峭度因子的性质, 当正常样本较多时, 其指标会集中在均值的一侧, 而异常电池会出现在均值的另一侧, 表现为离群现象。通过对信号进行重构并分析, 重构后的信号包含了更加突出的异常信息。为验证本文方法提取的特征是否发现异常信息, 将故障前后数据进行重构, 在此基础上提取偏度因子与峭度因子。设置窗口大小为 5, 即窗口大小为 50 s, 计算每个窗口的峭度因子。图 5a 为重构前峭度因子, b 为信号重构后峭度因子。在重构后的峭度因子第 250 个窗口 73 号电池峭度因子出现离群现象。由于 73 号电池峭度因子出现离群现象远早于 BMS 报警时间, 有可能是虚警。但是离群现象持续到第 400 个窗口结束。因此, 73 号电池在第 521 个窗口出现离群现象并不是虚警。79 号电池峭度因子在第 105 个窗口出现离群现象, 持续到 782 个窗口结束。峭度因子在提取重构信号故障特征放大了电池的不一致性, 为 LOF 算法计算离群点起到重要作用。




图5 重构前后的峭度因子

2.3 局部离群点检测

基于数据驱动的故障诊断方法，以其较高的故障诊断精度被广泛应用于工程领域。在众多诊断算法中，无监督机器学习算法比有监督机器学习算法具有更好的适应性，不需要对故障数据进行标注。局部离群因子是一种基于密度的无监督学习诊断算法，通过计算每个样本的离群值来实现异常检测，LOF算法的具体过程如下。

第1步：定义 $\text{dist}(i, j)$ 为 i 与 j 之间的距离， $d_k(i) = \text{dist}(i, j)$ ， $N_k(p)$ 为点 i 的第 k 距离的邻域，则 $N_k(p) \geq k$ 。

第2步：定义点 i 与 j 之间的可达距离为

$$\text{Rd}_k(i, j) = \max\{d_k(i), d_k(i, j)\}。$$

第3步：计算点 i 的局部可达密度 $\text{Lrd}_k(i)$

$$\text{Lrd}_k(i) = \frac{1}{\frac{\sum_{j \in N_k(i)} \text{Rd}_k(i, j)}{|N_k(i)|}}。 \quad (10)$$

第4步：计算点 i 的局部离群值 $\text{LOF}_k(i)$

$$\text{LOF}_k(i) = \frac{\frac{\sum_{j \in N_k(i)} \text{Lrd}_k(j)}{|N_k(i)|}}{\text{Lrd}_k(i)}。 \quad (11)$$

在故障诊断过程中，设置合理的阈值非常关键，阈值过高导致模型对故障不敏感，会因为未及时报警而产生严重后果；阈值过低会导致BMS产生大量的虚警，目前并没有完整理论分析阈值的设置。本文采用试错法设置固定阈值为-1.24，动态阈值为每个窗口的LOF异常得分的95%置信区间内的均值与固定阈值的和。故障电池的LOF值会超过动态阈值，因此，LOF算法动态阈值避免了阈值设置不合理造成的漏报、虚警等问题。图6为0~2 500个窗

口单体电池的LOF异常得分。BMS在第1 427窗口发出报警。11号电池在第500个窗口逐渐出现离群现象趋势，直到1 500个窗口停止，比BMS提前数十个窗口报警。22号电池在第1 300个窗口出现离群现象，直到第1 500个窗口停止，比BMS提前20个窗口停止离群现象。由于局部LMD算法重构后的信号放大了异常信息，因此，可以提前检测出故障电池11号与22号。




图6 LOF异常得分

3 诊断结果与分析

本节将对诊断结果进行分析，以验证本文算法的性能。总共12辆车，其中11辆车BMS发出报警，仅7号车未发生故障。采用4号车、8号车的数据验证本文方法对发生热失控故障的单体电池定位与故障检测的有效性；采用9号车的数据验证本文算法对突发故障检测与故障定位的可行性；采用7号车的数据验证本文算法的可靠性；同时采用1号车与6号车的数据进行对比试验，验证本文算法。由于数据维度不够，所以不能对故障进行分类，仅采用单体电池电压信号进行故障诊断，可以定位故障单体电池和故障检测。本文将对几种故障进行详细分析。

3.1 热失控故障诊断分析

图7为4号车热失控故障前后的数据图，图7a为原始电压信号，图7b为样本窗口各电池LOF异常得分，图7c为第7个样本窗口电池LOF异常得分，图7d为第63个样本窗口电池LOF异常得分。

66号电池在窗口为0时刻与其他电池没有差异,在第7个窗口开始出现离群值,本文算法触发报警,持续到第63个窗口结束。BMS系统在第42个样本窗口触发报警,本文算法比BMS提前34个样本窗

口时间。因此,4号车验证了本文峭度因子对于热失控电池故障可以起到放大异常信息的作用,LOF算法特性更容易检测故障和定位故障单体电池,避免了BMS不能提前检测故障的问题。

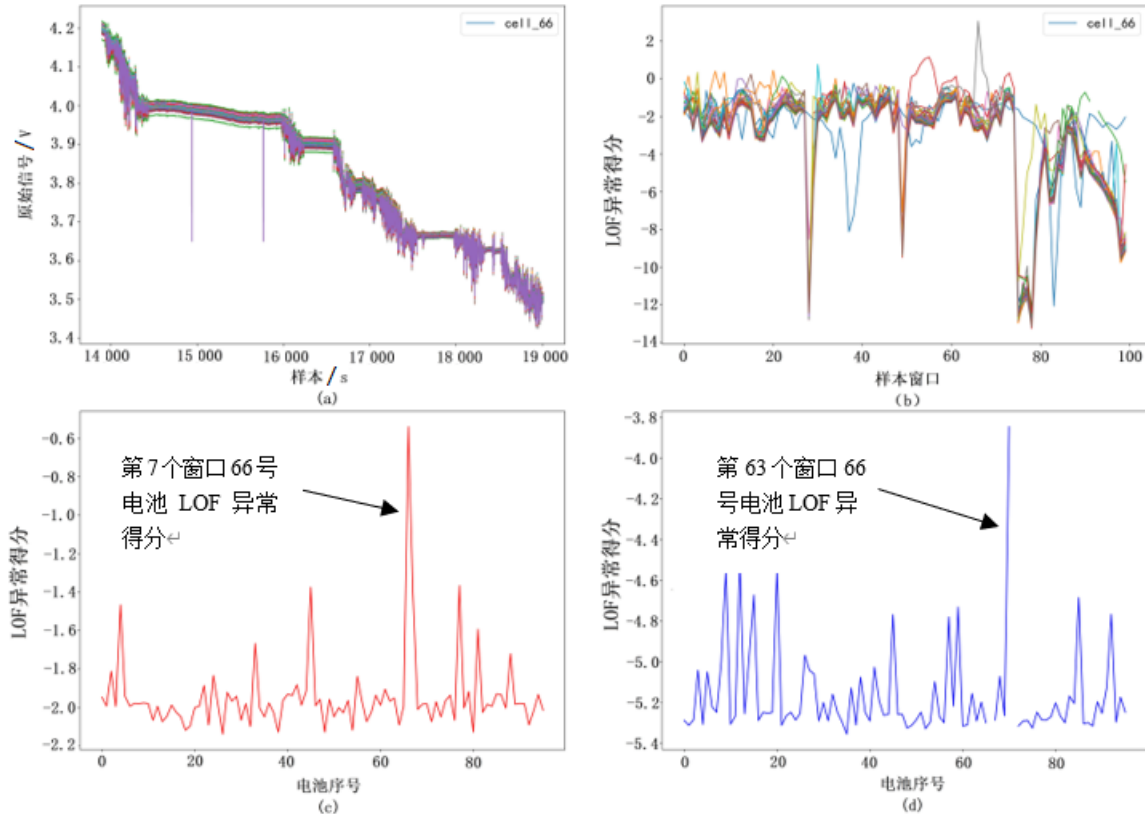


图7 4号车热失控故障图

图8为8号车热失控故障前后数据图,图8a为原始电压信号,图8b为样本窗口各电池LOF异常得分,图8c为第77个样本窗口电池LOF异常得分,图8d为第109个样本窗口电池LOF异常得分,与4号车相比,8号车电池一致性更差,8号车BMS在第95个样本窗口电压出现异常触发报警,之前的采样时刻电压无异常,但是峭度因子离群点在第77个样本窗口出现,持续到第110个样本窗口结束。进一步证明本文方法放大了原始电压信号的异常信息,同时证明了其预警出现热失控风险故障的可行性。

综上所述,通过对存在热失控故障的车辆进行验证,证明了峭度因子在提取故障特征的有效性与可行性,LOF动态阈值避免了设置阈值不合理而造成故障漏报、虚警等问题。同时也验证了本文提出

的LMD-LOF算法在电池热失控前后故障检测方面的有效性。

3.2 突发故障诊断分析

用9号车验证对于车辆突发故障的预警与诊断分析。图9a为原始电压曲线,图9b为峭度因子的LOF异常得分,图9c为第172个窗口的电池LOF异常得分,对应的样本点为860-865,图9d为第178个窗口LOF异常得分,对应的样本点为890-895。在第880个样本时刻,BMS发出单体电池欠压报警,直到第895个样本点结束报警。在故障发生之前,0号电池在第880个样本时刻前与其他电池相比没有任何异常,电池一致性较好。然而,从第880个样本点开始,0号电池突然下降到3.4V以下,然后逐渐恢复到3.588V。0号电池重构信号的峭度因子在第172个窗口出现离群现象,此时0号电池

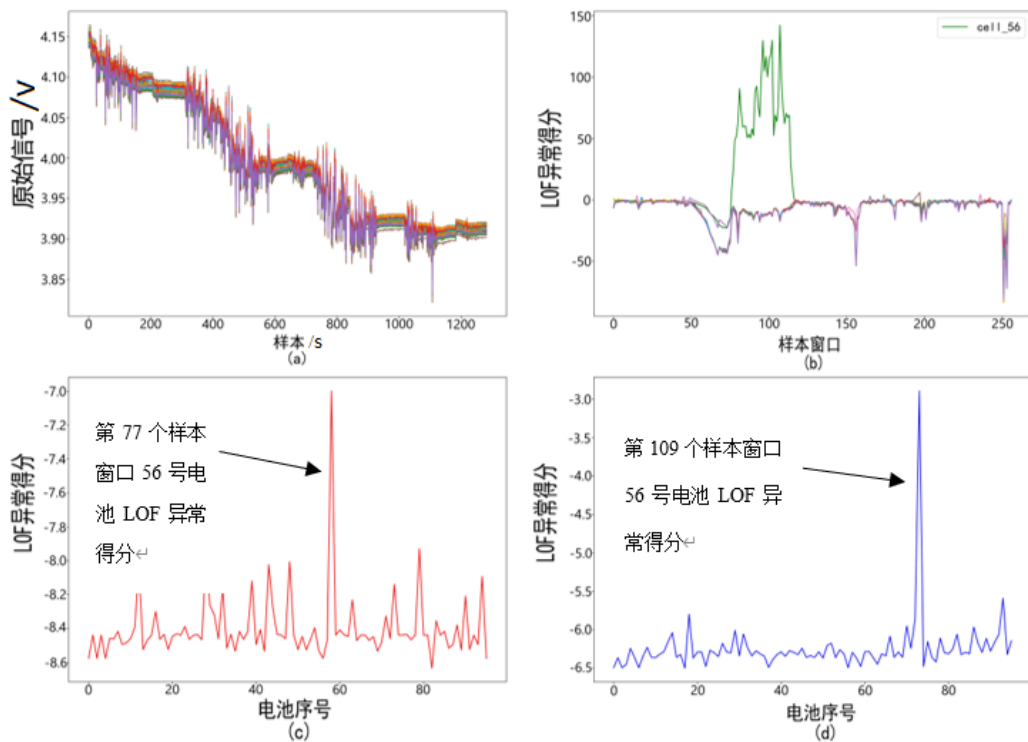


图8 8号车热失控故障图

峭度因子LOF异常得分上升,与其他电池比较上升更加明显,触发了LOF动态阈值,本文算法触发报警,持续到第178个窗口结束。随着使用时间的增加,0号电池在第900个采样点后与其他电池无异,LOF异常得分在第178个窗口之后与其他电池差距很小。因此,9号车验证了本文方法LMD-LOF对于突发故障可以起到放大特征的作用,更容易检测和定位故障,避免了BMS系统容易漏报小故障的问题。

3.3 可靠性分析

为验证本文的可靠性,选取7号车进行分析。7号车截止最后一帧数据采样时刻未出现故障。按照3.1~3.3节的步骤,首先设置滑动窗口大小为5,然后使用LMD算法对数据进行分解后重构,得到去除噪声影响后的电压信号。然后从降噪数据中提取峭度因子。最后将峭度因子作为特征输入到LOF算法中,LOF自适应阈值判断电池组中是否存在故障。如图10所示,一些电池在第752个窗口有所波动,可能是由电动汽车运行状态或LOF算法在计算异常得分过程中产生的波动造成,属于正常现象,

但是该电池并没有触发LOF算法的动态阈值。因此,7号车验证了本文所提LMD-LOF算法在电池故障诊断过程中的虚警率低,能快速反映电池电压的波动并及时触发报警,有利于电动汽车的安全。

3.4 与其他方法的对比

为了进一步突出LMD-LOF算法的特性,建立了一些对比试验。首先建立原始电压值进行对比试验,然后建立特征参数为偏度因子和峭度因子的对比试验。在进行算法对比时,每一组对比试验均为5组,选择了典型的一组进行展示。

本小节展示的数据为1号车,提取原始电压信号峭度作为特征输入,然后由LOF计算出个电池异常得分。图11a为原始电压信号峭度因子,图11b为重构信号峭度因子。重构信号放大了8号电池与其他电池之间的差异,提取了8号电池的故障特征。同时也放大了电池组之间的不一致性,因此,将原始信号峭度因子作为特征输入到LOF算法中,各电池之间会产生波动。如图11c中粉紫色曲线与绿色曲线,该电池异常得分高于其他电池,LOF动态阈值会将该电池作为故障电池,并触发报警。因

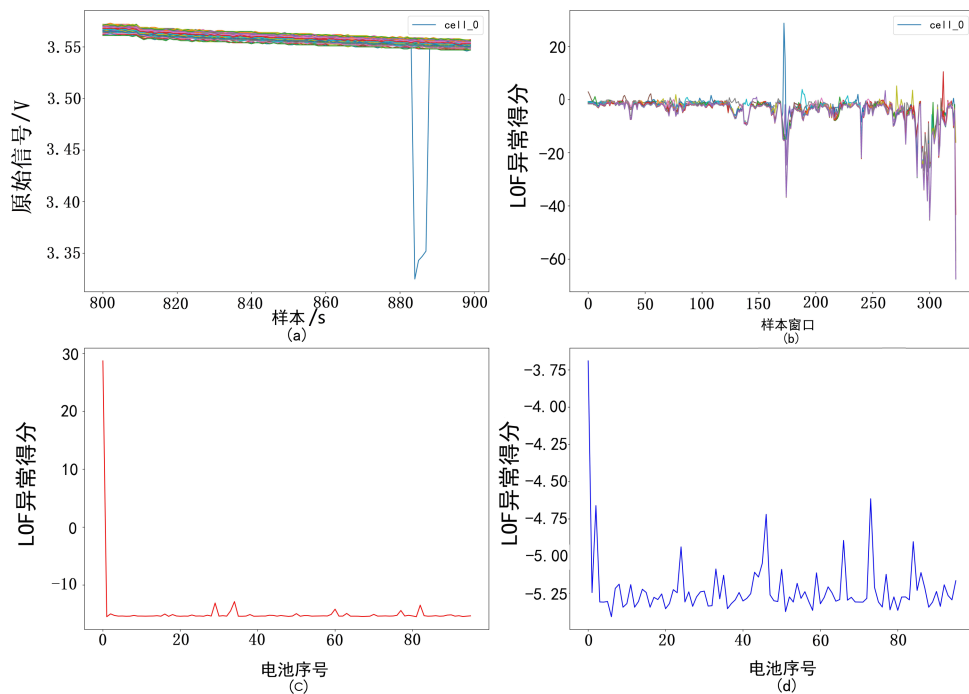


图9 9号车故障图




图10 7号车LOF异常得分

此,将原始信号峭度因子作为故障特征会导致漏报和虚警等问题。同时如图11d所示,8号电池在第1100个窗口开始出现离群现象,随着时间的推移,出现明显上升现象,直到第1300个窗口左右恢复正常值。因此,1号车验证了LMD重构信号特征可以有效放大故障信息,提取峭度因子作为故障特征参数输入到LOF算法中,进行故障诊断并定位故障单体电池。

分别采取峭度因子和广泛使用的偏度因子作为故障特征输入到LOF算法中,进行对比试验。使用6号车故障前后的数据作为对比试验数据。图12a为偏度系数,图12b为峭度系数,重构电压信号放大电池故障特征信息,偏度因子提取的故障特征比

较紊乱,并没有提取到13号电池的故障特征信息。图12c和d分别为偏度因子与峭度因子LOF异常得分。偏度因子作为特征参数输入到LOF算法中,LOF算法产生了诸多报警,但是仅13号电池发生故障,因此,这些报警均为虚警。峭度因子作为特征参数输入到LOF算法中,如图12d所示,在第1425个采样时刻LOF算法触发报警。但在第972个采样时刻,68号电池出现离群现象,在第974个采样时刻离群现象消失,LOF算法并未触发报警。因此,验证了本文所提算法采用峭度因子作为特征参数可以快速定位到故障与故障诊断,便于对故障电池的识别与定位。

4 结论

通过第4节对实际车辆采集数据进行的验证,本文提出的LMD-LOF算法对动力电池故障诊断是非常有效的。主要完成了以下工作:

- 1) 提出了基于LMD算法对原始电压信号的分解与重构,对数据进行了降噪处理,放大电池的故障信息,提高了故障诊断的精度;
- 2) 通过提取重构信号的峭度因子作为故障特征参数,可以有效提取故障电池的故障信息,放大

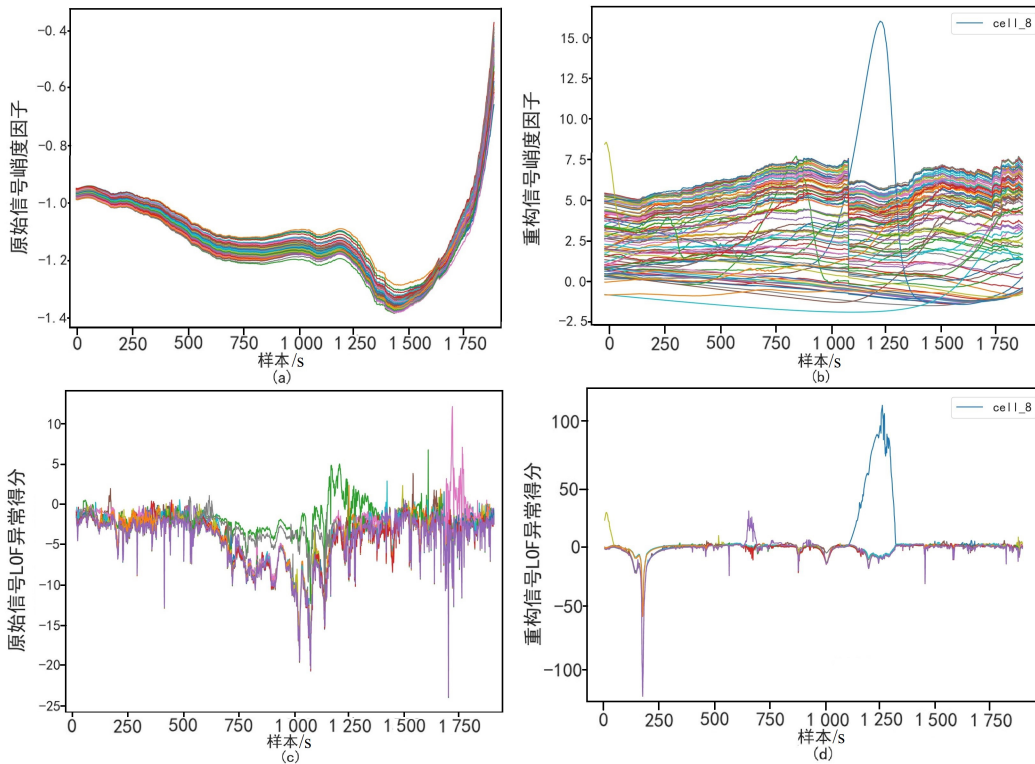


图 11 1号车原始信号与重构信号对比图

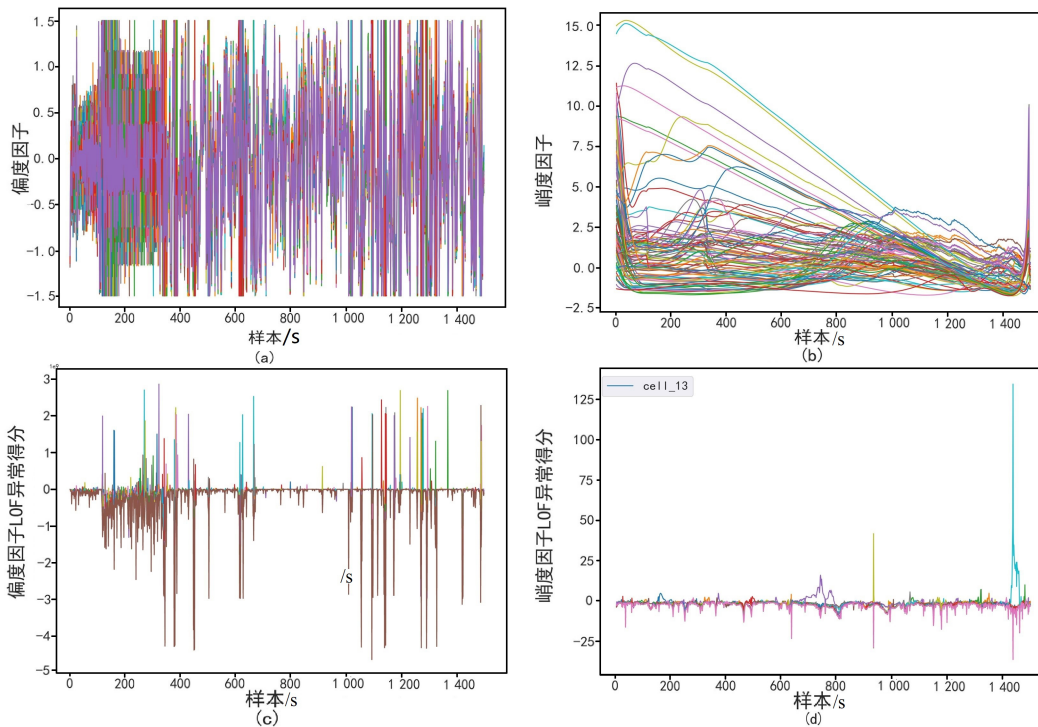


图 12 偏度因子与峭度因子对比

故障与非故障的差异，实现故障诊断；

3) 采用 LOF 算法对各电池峭度因子聚类得到各电池的异常得分，LOF 动态阈值可以输出故障单体电池，实现故障诊断与故障电池识别；

4) 以热失控为例验证了本文算法能定位故障单体电池，以突发故障为例验证了本文算法可以快速检测出故障，并通过实车数据验证了算法的可靠性与鲁棒性。

参考文献 (References)

- [1] 刘鹏, 吴志强, 张照生, 等. 基于电压频域特征和异常系数的动力电池故障诊断方法[J]. 中国公路学报, 2022, 35(8):89-104.
LIU Peng, WU Zhiqiang, ZHANG Zhaosheng, et al. A Fault Diagnosis Method for Power Battery Based on Voltage Frequency Domain Characteristics and Abnormal Coefficient [J]. China Journal of Highways, 2022, 35(8):89-104. (in Chinese)
- [2] WANG Zhenpo, HONG Jichao, LIU Peng, et al. Voltage Fault Diagnosis and Prognosis of Battery System Based on Entropy and Z-Score for Electronic Vehicles [J]. Applied Energy, 2017, 196:289-302.
- [3] CHANG Chun, TAO Chen, WANG Shaojin, et al. A Fault Diagnosis Method for Lithium Batteries Based on Optimal Variational Modal Decomposition and Dimensionless Feature Parameters[J]. Journal of Electrochemical Energy Conversion and Storage, 2023, 20(3):031004
- [4] 赵士博, 申彩英, 郭增江. 基于模糊神经网络的动力电池故障诊断研究[J]. 汽车实用技术, 2020, 45(18):7-8, 11.
ZHAO Shibo, SHEN Caiying, GUO Zengjiang. Research on Fault Diagnosis of Power Battery Based on Fuzzy Neural Network [J]. Automotive Practical Technology, 2020, 45(18):7-8, 11. (in Chinese)
- [5] 古昂, 张向文. 基于RBF神经网络的动力电池故障诊断系统研究[J]. 电源技术, 2016, 40(10):1943-1945.
GU Ang, ZHANG Xiangwen. Research on Fault Diagnosis System of Power Battery Based on RBF Neural Network [J]. Power Technology, 2016, 40(10):1943-1945. (in Chinese)
- [6] HONG Jichao, WANG Zhenpo, YAO Yongtao. Fault Prognosis of Battery System Based on Accurate Voltage Abnormity Prognosis Using Long Short-Term Memory Neural Networks[J]. Applied Energy, 2019, 251:113381.1-113381.14.
- [7] DENG Fuxiang, BIAN Yudong, ZHENG Haoran. Fault Diagnosis for Electric Vehicle Lithium Batteries Using a Multi-Classification Support Vector Machine[J]. Electrical Engineering, 2022, 104(3):1831-1837.
- [8] QIU Yan, SUN Jing, SHANG Yunlong, et al. A Fault Diagnosis and Prognosis Method for Lithium-Ion Batteries Based on a Nonlinear Autoregressive Exogenous Neural Network and Boxplot[J]. Symmetry, 2021, 13(9):1-16.
- [9] 董林鹭, 蒋若辰, 徐奴文, 等. 基于LMD-SVD的微震信号降噪方法研究[J]. 工程科学与技术, 2019, 51(5):126-136.
DONG Linlu, JIANG Ruochen, XU Nuwen, et al. Research on Microseismic Signal Denoising Method Based on LMD-SVD [J]. Engineering Science and Technology, 2019, 51(5):126-136. (in Chinese)
- [10] 曲洪权, 吉祥, 盛智勇, 等. 基于局部均值分解的样本熵特征提取研究及应用[J]. 激光与光电子学进展, 2022, 59(7):97-107.
QU Hongquan, JI Xiang, SHENG Zhiyong, et al. Research and Application of Sample Entropy Feature Extraction Based on Local Mean Decomposition [J]. Advances in Laser and Optoelectronics, 2022, 59(7):97-107. (in Chinese)
- [11] 严欣明, 杜璋昊, 毛小虎, 等. 基于局域均值分解的燃气管道泄漏定位技术[J]. 中国特种设备安全, 2020, 36(8):52-56.
YAN Xinming, DU Zhanghao, MAO Xiaohu, et al. Gas Pipeline Leakage Location Technology Based on Local Mean Decomposition [J]. China Special Equipment Safety, 2020, 36(8):52-56. (in Chinese)

作者简介



贾超明 (1998-), 男, 四川巴中人, 硕士研究生, 主要研究方向为车联网与大数据。

Tel: 18040464233

E-mail: xy052298@126.com

通信作者



胡杰 (1984-), 男, 湖南永州人, 博士, 教授, 主要研究方向为车联网与大数据、智能云诊断。

Tel: 13071237418

E-mail: auto_hj@163.com