

doi: 10.19562/j.chinasae.qcgc.2024.07.006

# 基于WOA-VMD和香农熵的锂电池早期故障诊断研究\*

胡杰<sup>1,2,3</sup>, 程雅钰<sup>1,2,3</sup>, 余海<sup>1,2,3</sup>, 贾超明<sup>1,2,3</sup>, 卿海华<sup>1,2,3</sup>

(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. 能源与智能网联车工程技术研究中心, 武汉 430070)

**[摘要]** 针对当前电池管理系统无法诊断早期故障的问题, 本文提出了一种基于WOA-VMD和香农熵的锂电池早期故障诊断方法。首先引入鲸鱼优化算法对变分模态分解算法进行参数寻优, 提高变分模态分解算法的分解效果, 使之分解得到包含更多故障特征信息的本征模态函数分量, 再对单体电池电压信号进行分解重构, 减少测量噪声和额外激励电压造成的影响。进而采用滑动窗口计算单体电压的香农熵极差和单体电压离差的总体香农熵, 设置合适的阈值进行早期故障诊断。经过实际车辆数据验证, 该方法可以提前10 min左右进行故障预警, 且对于无故障车辆不会产生虚假预警, 具有较强的鲁棒性和可靠性。

**关键词:** 鲸鱼算法; 变分模态分解算法; 香农熵; 故障诊断

## Research on Early Fault Diagnosis of Lithium Battery Based on WOA-VMD and Shannon Entropy

Hu Jie<sup>1,2,3</sup>, Cheng Yayu<sup>1,2,3</sup>, Yu Hai<sup>1,2,3</sup>, Jia Chaoming<sup>1,2,3</sup> & Qing Haihua<sup>1,2,3</sup>

1. Wuhan University of Technology, Hubei Key Laboratory of Modern Automotive Parts Technology, Wuhan 430070;

2. Wuhan University of Technology, Hubei Collaborative Innovation Center for Automotive Parts Technology, Wuhan 430070;

3. Hubei Engineering Technology Research Center for New Energy and Intelligent Connected Vehicles, Wuhan 430070

**[Abstract]** A lithium battery early fault diagnosis method based on WOA-VMD and Shannon entropy is proposed in this paper to solve the problem of current battery management systems being unable to diagnose early faults. Firstly, the whale optimization algorithm is introduced to optimize the parameters of the variational mode decomposition algorithm to improve its decomposition performance and obtain intrinsic mode function components containing more fault feature information. Then, the voltage signal of the individual battery is decomposed and reconstructed to reduce the impact of measurement noise and additional excitation voltage. Furthermore, a sliding window is used to calculate the Shannon entropy range of individual voltage and the overall Shannon entropy of individual voltage dispersion to set appropriate thresholds for early fault diagnosis. After verification with actual vehicle data, this method can provide fault warning about 10 minutes in advance without generating false warnings for vehicles without faults. It has strong robustness and reliability.

**Keywords:** whale optimization algorithm; variational mode decomposition algorithm; Shannon entropy; fault diagnosis

\* 广西科技重大专项(2023AA03009)资助。

原稿收到日期为2023年12月27日, 修改稿收到日期为2024年02月28日。

通信作者: 胡杰, 教授, 博士生导师, 博士, E-mail: auto\_hj@163.com。

## 前言

在全球绿色低碳转型的背景下,我国的新能源汽车产业快速发展。动力电池作为新能源汽车的关键核心部件,其安全问题是电动汽车发展的基础。在动力电池故障诊断方面,国内外学者采用的故障诊断方法主要有基于知识、基于模型和基于数据驱动3种方法。其中,基于知识的锂电池故障诊断算法可以分为图论法、专家系统法和模糊逻辑法。武美君<sup>[1]</sup>基于电池系统的仿真模型,提出了基于有向图的故障定位方法;刘晓俊<sup>[2]</sup>基于动力电池工作原理和专家经验,提出了知识库建立方法并构建了综合判断推理机模型,而马宗钰等<sup>[3]</sup>提出了基于模糊逻辑理论的故障诊断方法。基于模型的故障诊断方法主要包括数学模型、等效电路模型和电化学模型, Marcicki 等<sup>[4]</sup>通过耦合线性奇偶方程和滑模观测器,提出一种基于电流残差和电压残差的电池传感器故障诊断方法, Masri 等<sup>[5]</sup>则通过构建等效电路模型,提出了一种锂电池的传感器故障诊断方法,曾港辉<sup>[6]</sup>则通过建立锂电池电化学-热耦合模型,提出了锂电池微过充故障预测算法。以上两种方法都能实现较好的故障诊断效果,但基于知识的故障诊断方法自适应性差,且专家经验和知识难以获取,而基于模型的故障诊断方法容易受到模型不确定性和训练数据噪声干扰的影响,难以准确建模,故基于数据驱动的方法应运而生。

基于数据驱动的故障诊断方法主要通过直接处理分析真实数据实现故障检测和故障隔离。例如, Shang 等<sup>[7]</sup>提出了一种基于改进样本熵的电池早期故障实时多故障诊断方法。此外,一些学者采用神经网络进行故障诊断,例如小波神经网络(wavelet neural network, WNN)<sup>[8]</sup>、支持向量机(support vector machines, SVM)<sup>[9]</sup>、长短期记忆神经网络(long short term memory, LSTM)<sup>[10]</sup>和径向基函数(radial basis function, RBF)神经网络<sup>[11]</sup>等算法。经过实验数据验证,以上算法都具有很好的故障诊断效果,但是不适用于真实车辆的稀疏数据。

基于实际车辆数据,大多数研究者采用信号处理和数理统计的方法进行故障诊断,其中 Li 等<sup>[12]</sup>提出了一种基于 DBSCAN 聚类的三元锂电池系统热失控诊断方法,提取电压二维故障特征,采用 DBSCAN 聚类对异常单体进行识别和预警。Li 等<sup>[13]</sup>则提出了

一种基于经验模态分解(empirical mode decomposition, EMD)和样本熵的新型故障检测方法,采用经验模态分解对电池电压信号进行分解降噪并提取故障特征,最后利用故障特征的样本熵值对电池故障进行检测定位。以上方法均以单体电池的特性作为研究对象,未全面考虑整个电池的特性。

本文基于单体电池电压的实车数据,计算单体电池香农熵极差和整个电池的总香农熵,用于电池早期故障诊断。首先通过鲸鱼算法(whale optimization algorithm, WOA)优化变分模态分解算法(variational mode decomposition, VMD),再对单体电池电压进行分解降噪,重构得到新的数据集,进而分别计算单体电池电压的香农熵极差和离差的香农熵,结合故障的分级标准和阈值,实现电池故障的分级诊断。

## 1 算法原理概述

### 1.1 VMD 算法原理

VMD 算法由 Konstantin Dragomiretskiy<sup>[14]</sup>于 2014 年提出,该算法能够将复杂的信号分解问题转化成了一个变量模型,把复杂的信号分解成为若干个调幅调频的分量信号并获得最优解,适用于处理非线性非平稳信号。相比于其他常见的 EMD 分解和集合经验模态分解(ensemble empirical mode decomposition, EEMD)方法, VMD 算法通过引入约束条件和正则化项,能够很好地解决模态混叠问题,提高算法的稳定性,并且 VMD 通过引入辅助变量和快速傅里叶变换等技术,能够加快分解的速度,降低计算复杂度。同时, VMD 将信号分解为多个模态函数,每个模态函数代表了信号中的一个局部频率成分,其物理意义明确。其本征模态函数(intrinsic mode function, IMF)的计算公式为

$$u_k(t) = A_k(t) \cdot \cos(\phi_k(t)) \quad (1)$$

式中:  $A_k(t)$  为幅值;  $t$  为时间变量;  $\phi_k(t)$  为相位函数。

该算法主要包括构建变分模型和求解变分模型两个步骤。构建变分模型步骤如下:(1)通过 Hilbert 变换分析模态函数的分解信号  $u_k(t)$ , 获得  $u_k(t)$  的单边频谱;(2)引入指数因子,调制每个模态函数的频谱至各自对应的基频带;(3)采用 Gaussian 平滑解调分解信号  $u_k(t)$ , 即  $L^2$  范数梯度的平方,获得  $u_k(t)$  的估计带宽,其约束变分模型表达式如式(2)所示。求解变分模型步骤如下:(1)通过引入二次惩罚因子  $\alpha$

和拉格朗日乘数 $\lambda$ ,使得约束变分问题变为无约束问题;(2)利用交替方向乘子算法不断更新 $u_k$ 和 $\omega_k$ ,使原始信号分解成 $k$ 个模态函数,同时找到拉格朗日函数的极小值,获得最优解。其中, $u_k$ 和 $\omega_k$ 的更新公式如式(3)和式(4)所示。

$$\begin{cases} \min_{(u_k), (\omega_k)} \left\{ \sum_k \left\| \partial_k \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\| \right\} \\ \text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (2)$$

式中: $\partial_k$ 为偏导数; $\delta(t)$ 为单位脉冲函数; $j$ 为虚数单位; $\omega_k$ 为各模态分量的中心频率; $u_k$ 为各模态分量。

$$u_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{\mu}_k^n(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^n(\omega)|^2 d\omega} \quad (4)$$

VMD算法可以很好地避免信号分解时模态混叠和端点效应等情况,且分解重构后的信号具有良好的抗噪声性和非平稳性。该算法的参数设置决定了信号降噪的效果,故本文引入正余弦优化算法优化VMD算法的参数选择。

## 1.2 WOA算法理论

WOA算法是Mirjalili等<sup>[15]</sup>于2016年提出的一种新的群体智能优化算法,通过模拟座头鲸特有的狩猎行为,在解空间中不断更新鲸鱼的位置,获得全局最优解。其算法包括包围猎物、螺旋攻击和随机搜索3种位置更新阶段,3个阶段的数学模型如式(5)~式(7)所示。

$$\begin{cases} D = |C \cdot X_t^* - X_t| \\ X_{t+1} = X_t - A \cdot D \end{cases} \quad (5)$$

$$\begin{cases} D_1 = |X_t^* - X_t| \\ X_{t+1} = D_1 \cdot e^{bl} \cdot \cos(2\pi l) + X_t^* \end{cases} \quad (6)$$

$$\begin{cases} D_2 = |C \cdot X_t^{\text{rand}} - X_t| \\ X_{t+1} = X_t^{\text{rand}} - A \cdot D_2 \end{cases} \quad (7)$$

式中: $D$ 、 $D_1$ 、 $D_2$ 分别表示包围猎物、螺旋攻击和随机搜索3个不同阶段当前鲸鱼个体到目标位置的距离; $X_t^*$ 、 $X_t$ 、 $X_t^{\text{rand}}$ 分别表示第 $t$ 次迭代时最优的位置向量、鲸鱼个体的位置向量和随机选取的鲸鱼个体位置向量; $b$ 则为一个常数,用于定义对数螺旋形状; $l$ 为 $[-1, 1]$ 的随机数; $A$ 、 $C$ 为系数向量,用于控制鲸鱼游走方式,如式(8)所示。

$$\begin{cases} A = 2a \cdot r - a \\ C = 2r \\ a = 2 - \frac{t}{T_{\max}} \end{cases} \quad (8)$$

式中: $r$ 为 $[0, 1]$ 的随机向量; $a$ 为控制参数; $T_{\max}$ 是最大迭代次数。

WOA算法的流程如图1所示。

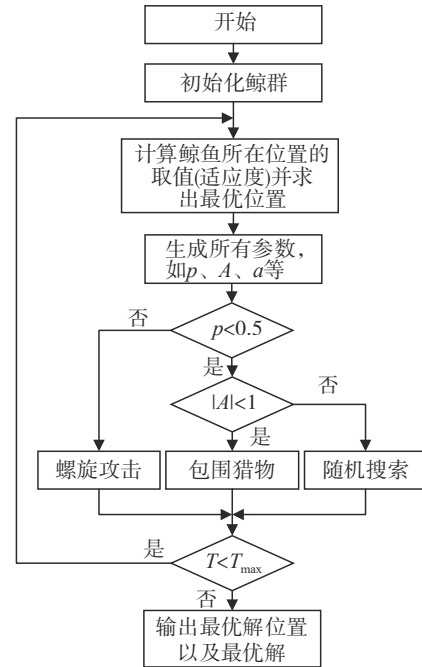


图1 WOA算法流程图

## 1.3 基于WOA算法优化VMD算法

将最小平均包络熵作为WOA算法的适应度函数,自适应寻找最优的模态数量参数 $k$ 和惩罚因子参数 $\alpha$ ,构建VMD模型对单体电池电压进行分解重构,实现数据去噪。具体算法步骤如下:(1)初始化一些参数,设置分解个数 $k \in [3, 10]$ ,二次惩罚因子 $\alpha \in [1\ 000, 3\ 000]$ ,最大迭代次数 $T$ 为20;(2)计算重构信号的适应度函数值,即最小平均包络熵;(3)对模态数量参数 $k$ 和惩罚因子参数 $\alpha$ 进行迭代寻优;(4)输出最优的 $(k, \alpha)$ 及全局最优的适应度函数值;(5)采用最优 $(k, \alpha)$ 参数,利用VMD算法对信号进行分解重构,去除噪声,得到新的信号。

## 1.4 香农熵理论

香农熵,也称信息熵,由信息论的创始人Shannon在《通信的数学理论》<sup>[16]</sup>中首次提出,用于表示随机变量不确定性,即信息熵越大则变量的不确定性越大,包含的信息量越大。香农熵定义如下:

$$H(X) = -\sum_{i=1}^n p(x_i) \log p(x_i) \quad (9)$$

式中 $p(x_i)$ 代表随机事件 $x_i$ 的概率。

## 2 数据分析及数据处理

### 2.1 数据获取

本文采用新能源汽车国家监测与管理平台的10辆汽车车辆历史运行数据进行动力电池故障诊断研究,其动力电池类型为三元锂电池,数据采集时间为2019年11月到2020年6月,采集周期为10 s,约545万条数据。其中主要参数信息如表1所示。

表1 数据部分参数

数据字段名称	数据说明
total_volt	总电压/V
total_current	总电流/A
cell_volt_list	单体电池电压值列表
cell_temp_list	单体电池温度值列表
max_cell_volt	单体电池电压最高值/V
min_cell_volt	单体电池电压最低值/V
alarm_info	通用报警标志
max_alarm_lvl	最高报警等级

### 2.2 数据分析

本文以单体电池电压作为研究对象,进行电池早期故障诊断。电池在制造过程中存在初始不一致性,并且锂电池的使用会加剧电池不一致性,使单体电池的输出电压存在差异,最终导致电池产生过充、过放电或内部短路等故障。在电池充放电过程中,单体电池的输出电压会产生上升或下降的趋势,并伴随单体电池不一致性造成的小范围波动。当电池存在故障时,单体电池电压会出现大范围波动,研究电压的波动程度,能够诊断电池早期故障。图2和图3分别为4号车辆停车静置时存在故障报警和无故障报警时的部分单体电压变化情况。由图2和图3对比可知,在车辆未发生故障时,4号车的电压只有小范围波动,且单体电池电压曲线保持一定相似性,在车辆发生故障时,部分单体电压出现跳变或大范围波动的情况。

### 2.3 数据处理

为了便于后续电压数据处理,需要对原始数据基于车辆状态、充电状态进行片段划分。将数据分为行驶片段、停车充电片段和停车静置片段,而后将单体电池电压值列表进行切片处理,提取95个单体

电池电压。

为了充分考虑汽车充放电时的电压波动,须选择数据段同时包含充电片段、静置片段和放电片段,因此选择4号车包含单体热失控故障报警的2644条数据进行研究。采用WOA优化后的VMD算法分解95个单体电池电压,其中所有单体电池电压信号分解为7个IMF和一个残余分量Res,如图4所示,其中蓝色部分为车辆行驶片段,红色部分为车辆静置片段,绿色部分为车辆停车充电片段。




图2 4号车辆静置时存在故障报警的单体电压




图3 4号车辆静置时无故障报警的单体电压

分解后的信号往往分为原信号相似的主要信号模态和与原信号相差大的噪声模态,然而噪声模态中其实还含有一些重要信息,因此仅对主要信号模态进行重构会丢失部分故障信息,并且不同的单体电池分解得到不同数量的主要信号模态和噪声模态,考虑到仅采用主要信号模态重构后的信号会对单体电池之间的不一致性产生较大影响,故本文重构信号采用IMF1到IMF7的总和,得到一个原信号的近似信号,如图5所示。图6为原始信号。对比图5和图6可见,采用优化后的VMD算法分解重构的方法可以增加故障时电池单体电压的不稳定程度,同时可以降低正常情况下电池单体电压的波动程度。




图4 单体电池电压信号分解的8个分量




图5 重构后的单体电池电压




图6 原始单体电池电压

### 3 早期故障检测方法分析

为了从单体电池电压数据中提取有效的故障特

征,首先将单体电池电压数据转换成矩阵,采用一维滑动窗口计算所有单体电池电压的香农熵和极差,随后计算每个单体电池的离差构成新的矩阵,利用二维滑动窗口计算电压离差的总体香农熵,最后设置适当的香农熵极差阈值和总体香农熵阈值进行电池早期故障诊断。

采用一维滑动窗口计算单体电池电压的香农熵时,设置步长为1,窗口大小为30,即采用5 min前各单体电池电压计算单体电压香农熵,再计算香农熵极差 $SE_i^{dev}$ ,以表征单体电池间的最大差异,计算公式如下:

$$SE_i^{dev} = SE_i^{max} - SE_i^{min} \quad (10)$$

式中: $SE_i^{max}$ 是第*i*时刻单体电池电压的最大香农熵; $SE_i^{min}$ 是第*i*时刻单体电池电压的最小香农熵。

在计算单体电压的离差值时,为了降低个别极值的影响,采用95%的置信区间内数据的平均值替代原始平均值。再将单体电压的离差数据转换成新的矩阵,采用相同的步长和窗口的二维滑动窗口计算单体电池电压离差的总体香农熵 $SE_i^{total}$ 。

阈值是电池故障检测的关键参数,本文利用大量电池历史运行数据进行训练分析,确定香农熵极差阈值为2,总体香农熵阈值为4.7。为了确定故障的严重程度和影响范围,本文定义3个故障等级,其故障分级准则如表2所示。

若香农熵极差和总体香农熵均未触发报警,则表示当前电池系统处于正常状态;若香农熵极差或总体香农熵触发报警,则代表电池系统处于一级故障状态,表示此时电池系统可能存在一些早期微小故障,不影响车辆运行,但若后期不加以干涉,容易

表2 电池故障分级准则

香农熵极差 $SE_i^{dev}$	总体香农熵 $SE_i^{total}$	诊断结果
$SE_i^{dev} < 2$	$SE_i^{total} < 4.7$	正常
	$SE_i^{total} > 4.7$	一级预警
$SE_i^{dev} > 2$	$SE_i^{total} < 4.7$	
	$SE_i^{total} > 4.7$	二级预警

引发较为严重的故障;若香农熵极差或总体香农熵均触发报警,则表示电池系统触发二级故障报警,说明此时电池系统存在严重的非一致性故障,可能存在电池内短路、过充或过放等情况,甚至会引发热失控。

## 4 结果分析

### 4.1 故障检测结果分析

将4号车包含热失控故障的一个完整充放电循环片段数据进行VMD算法去噪,后采用滑动窗口计算所得的香农熵结果如图7所示,其中红色的线代表各时刻单体电池电压离差的总体香农熵,黑色的线代表单体电池电压香农熵的极差。在前30条数据中,由于此时计算香农熵的数据量小于30,所以此时的单体电压香农熵极差值和电池电压离差的香农熵略低于其他时刻的正常值,故不作为参考。

根据图7所示,在第900条数据时,此时存在制动能量回收,造成单体电池电压存在上下波动,致使电池电压的总体香农熵产生小幅上升,但单体之间未产生较大不一致性,同时单体电压香农熵极差处于正常波动,两者均未超过阈值,未触发报警。而在第2499条数据,即BMS报警前11 min 12 s时,单体电压香农熵极差为2.22,说明本文提出的方法已经检测出锂电池存在较差的非一致性故障,发出一级报警。随着电池电压离差的香农熵不断增大,在第2517条数据时,单体电压香农熵极差第一次超过4.7,电池系统从一级报警变成二级报警,说明此时车辆发生严重故障,根据实际车辆数据显示,此时车辆逐渐发生热失控故障,BMS随后产生单体欠压报警、单体一致性报警、高温报警和温度差异报警等一系列报警。

### 4.2 故障检测方法鲁棒性验证

采用多辆不同故障车辆进行鲁棒性验证,验证结果如表3所示。本文提出的方法能够提前10 min左右对大部分电压故障进行预警。

其中7号车的验证数据共4270条,包含单体欠压和单体不一致性故障的一个完整充放电循环片

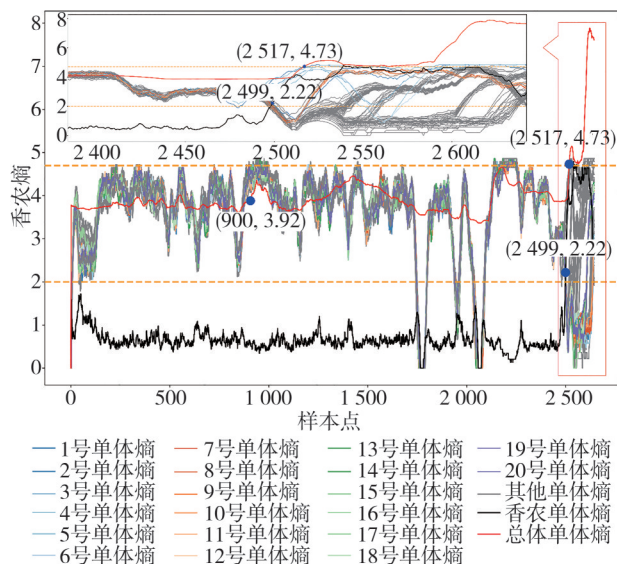


图7 4号车单体电池电压的香农熵

表3 其他故障车辆预警结果

故障车辆	故障类型	预警时间
1号车	单体电池欠压	8 min 56 s
2号车	单体电池过压	11 min 02 s
6号车	车载储能装置过压	9 min 23 s
7号车	单体电池欠压、电池单体一致性差	8 min 24 s

段。经过处理和计算,获取的香农熵结果如图8所示,在第3902条数据,即BMS产生单体欠压报警的前8 min 24 s时,电池电压离差香农熵为4.73,第一次超过阈值,而单体电压香农熵极差未超过阈值,可见此时各单体电池电压存在相似的波动趋势并处于正常的波动范围,但单体电池之间存在不一致性,说明此时电池单体可能存在欠压或者过压的情况,但无法确定具体故障类型。随后在第4240条数据时,单体电压香农熵极差达到2.04,首次超过阈值,说明此时电池的电压之间存在严重不一致性,已造成较大影响,此时据BMS产生电池单体一致性差报警提前10 min。由于电池之后进入充电过程,各单体电压迅速上升,并表现出较小的差异,故而单体电压香农熵和电压离差香农熵迅速下降至正常范围。由此可以证明该方法能够提前10 min左右对故障进行预警,并且对于恢复至正常范围的电压不会产生虚警。

### 4.3 故障检测方法可靠性验证

为了验证故障检测方法的可靠性,选择了从未发生BMS报警的5号车的数据进行多次验证。在多组数据中,均未发生报警情况。以第23组数据为




图8 7号车单体电池电压的香农熵

例,具体结果如图9所示。在这组数据中,单体电压的香农熵极差最大值为1.47,出现在第1 025条数据处。同时,单体电压离差的香农熵值最大为4.38,出现在第2 034条数据处。值得注意的是,这两个数值均未超过设定的阈值,因此未触发报警。通过这些数据分析,证明了在车辆未发生故障的情况下,该故障检测方法不会误报警,表现出良好的可靠性。




图9 5号车单体电池电压的香农熵

#### 4.4 故障检测方法对比分析

为了体现本文提出的故障诊断方法的优势,对比基于香农熵和z分位数的故障检测方法,其中z分

位数的阈值是由大量历史数据训练分析得到的。以5号车电池正常状态下单体电压数据作为研究对象,将电压数据进行相同的降噪处理后,分别采用基于香农熵和z分位数的故障诊断方法和本文提出的故障诊断方法进行验证,结果如图10和图11所示。对比两图可知,基于香农熵和z分位数的故障检测方法在第596、1 290和2 238等多个样本点检测出异常,发生虚假报警,而本文提出的方法检测出单体电压香农熵极差最大值为1.56,单体电压离差的香农熵值最大值为4.51,未触发报警。因此验证了本文提出的基于WOA-VMD和香农熵的电池故障诊断方法的有效性。

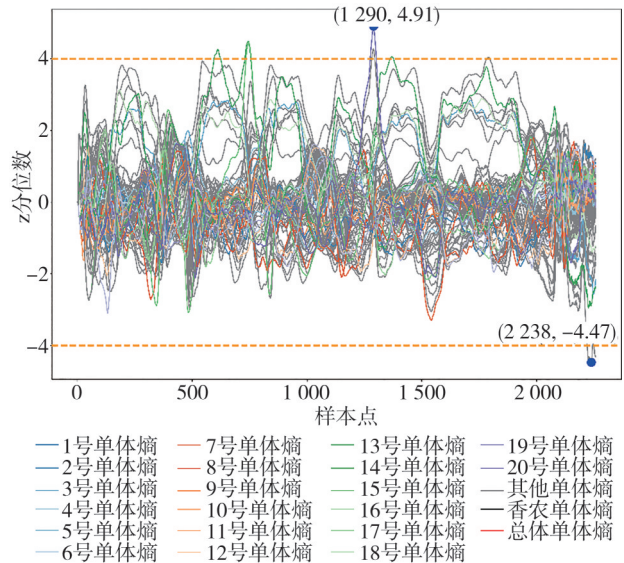


图10 基于香农熵和z分位数的电池故障诊断

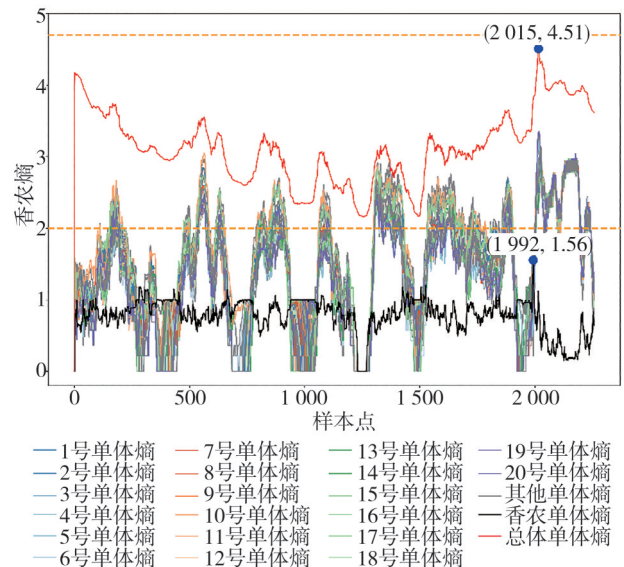


图11 基于WOA-VMD和香农熵的电池故障诊断

## 5 结论

本文所提出的故障预警方法简单便捷,易于在线实现。采用WOA优化后的VMD算法进行数据去噪,有效避免了模态混叠、过包络、欠包络、边界效应和人为选取参数影响分解的效果等问题,同时保留了原始信号中的故障信息。并且本文提出的方法仅采用前5 min的历史单体电池电压数据,计算单体电压的香农熵极差和单体电压离差的香农熵进行阈值诊断,可以提前10 min左右进行故障预警。经过实际车辆数据验证,该方法对无故障车辆不会产生虚假预警,具有很好的鲁棒性和可靠性。与基于香农熵和 $z$ 分位数的故障检测方法对比,本文提出的方法具有更好的有效性。

### 参考文献

- [1] 武美君. 基于数据驱动与有向图模型的动力电池系统故障诊断研究[D]. 武汉: 武汉理工大学, 2021.  
WU M J. Research on fault diagnosis of power battery system based on data-driven and directed graph models [D]. Wuhan: Wuhan University of Technology, 2021.
- [2] 刘晓俊. 电池故障智能诊断系统的研究与实现[D]. 北京: 北京邮电大学, 2011.  
LIU X J. Research and application of intelligent battery fault diagnosis system [D]. Beijing: Beijing University of Posts and Telecommunications, 2011.
- [3] 马宗钰, 兰海潮, 宋若昂, 等. 基于支持向量机的动力电池故障诊断[J]. 汽车实用技术, 2021, 46(2): 5-7.  
MA Z Y, LAN H C, SONG R Y, et al. Power battery fault diagnosis based on Support Vector Machine [J]. Practical Automotive Technology, 2021, 46(2): 5-7.
- [4] MARCICKI J, ONORI S, RIZZONI G. Nonlinear fault detection and isolation for a lithium-ion battery management system [C]. ASME 2010 Dynamic Systems and Control Conference, Volume 1. Cambridge, Massachusetts, USA: ASMEDC, 2010: 607-614.
- [5] MASRI B A, SHEIKH H A, MOUBAYED N. Sensor fault detection of lithium-ion batteries based on extended Kalman filter [C]. 2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE). Istanbul, Turkey: IEEE, 2020: 1-5.
- [6] 曾港辉. 锂离子电池微过充电化学-热耦合模拟与安全预警研究[D]. 长沙: 湖南大学, 2022.  
ZENG G H. Electrochemical thermal coupling simulation and safety warning for slight overcharge of lithium-ion battery [D]. Changsha: Hunan University, 2022.
- [7] SHANG Y L, LU G P, KANG Y Z, et al. A multi-fault diagnosis method based on modified sample entropy for lithium-ion battery strings [J]. Journal of Power Sources, 2020, 446: 227275.
- [8] YAO L, XIAO Y Q, GONG X Y, et al. A novel intelligent method for fault diagnosis of electric vehicle battery system based on wavelet neural network [J]. Journal of Power Sources, 2020, 453: 227870.
- [9] YAO L, FANG Z P, XIAO Y Q, et al. An intelligent fault diagnosis method for lithium battery systems based on grid search support vector machine [J]. Energy, 2021, 214: 118866.
- [10] HONG J C, WANG Z P, YAO Y T. Fault prognosis of battery system based on accurate voltage abnormality prognosis using long short-term memory neural networks [J]. Applied Energy, 2019, 251: 113381.
- [11] WANG J, ZHANG S L, HU X. A fault diagnosis method for lithium-ion battery packs using improved RBF neural network [J]. Frontiers in Energy Research, 2021, 9: 702139.
- [12] 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.
- [13] LI X Y, DAI K W, WANG Z P, et al. Lithium-ion batteries fault diagnostic for electric vehicles using sample entropy analysis method [J]. Journal of Energy Storage, 2020, 27: 101121.
- [14] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [15] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.
- [16] SHANNON C E. A mathematical theory of communication [J]. The Bell System Technical Journal, 1948, 27(3): 379-423.
- [23] 王志奎, 段兴潮. 转子流量计气体流量校正公式的推导和讨论 [J]. 工业仪表与自动化装置, 1988(5): 11-13, 34.  
WANG Z K, DUAN X C. Derivation and discussion of gas flow correction formula for rotary flow meters [J]. Industrial Instrumentation & Automation, 1988(5): 11-13, 34.
- [24] 吕平, 孙昕, 许有伟, 等. 车用燃料电池堆低温停机吹扫试验研究 [J]. 汽车工程, 2023, 45(11): 2123-2129.  
LÜ P, SUN X, XU Y W, et al. An experimental study on low temperature shutdown and purging of vehicle fuel cell stack [J]. Automotive Engineering, 2023, 45(11): 2123-2129.

(上接第1156页)