DOI：10.13234/j.issn.2095-2805.2026.4.169 **中图分类号**：TM912 **文献标志码**：A

基于变分模态分解与随机森林的锂离子电池故障诊断方法研究

王君瑞，季长江(中国电源学会学生会员)，李 进，谭 露，朱旭强
(北方民族大学电气信息工程学院，银川 750000)

摘要：为保证储能电站和新能源汽车的安全运行，针对锂离子电池内短路故障引发的热失控现象，提出麻雀搜索算法优化变分模态分解 SSA-VMD (sparrow search algorithm optimized variational mode decomposition)和随机森林 RF (random forest)算法的故障诊断方法。首先通过 SSA 寻找 VMD 分解层数 K 和惩罚因子 α 的最优参数组合，将锂离子电池内短路故障信号与正常信号分解出多个模态分量 IMF (intrinsic mode function)；其次，计算各 IMF 的样本熵值作为特征向量；最后将特征向量分别输入至支持向量机 SVM(support vector machine)故障诊断模型与 RF 故障诊断模型中进行故障诊断。结果表明，SVM 故障诊断率为 66.667 0%、RF 故障诊断率为 96.666 7%，锂离子电池内短路故障得到了有效识别。

关键词：锂离子电池；内短路故障；故障诊断；变分模态分解；随机森林

Research on Fault Diagnosis Method for Lithium-ion Battery Based on Variational Mode Decomposition and Random Forest

WANG Junrui, JI Changjiang, *Student Member*, *CPSS*, LI Jin, TAN Lu, ZHU Xuqiang
(School of Electrical and Information Engineering, North Minzu University, Yinchuan 750000, China)

Abstract: To ensure the safe operation of energy storage power stations and new energy vehicles, aimed at the thermal runaway phenomenon caused by internal short-circuit faults in lithium-ion batteries, a fault diagnosis method based on sparrow search algorithm optimized variational mode decomposition (SSA-VMD) and random forest (RF) algorithm is proposed. First, SSA is used to find the optimal parameter combination of VMD decomposition layer K and penalty factor α, and the internal short-circuit fault signal and normal signal of lithium-ion batteries are decomposed into multiple intrinsic mode functions (IMF). Second, the sample entropy value of each IMF is calculated as an eigenvector. Finally, the eigenvectors are input into the support vector machine (SVM) fault diagnosis model and the RF fault diagnosis model for fault diagnosis, respectively. Results show that the fault diagnosis rate of the SVM model is 66.667 0% and that of the RF model is 96.666 7%, indicating that the internal short-circuit fault in lithium-ion batteries is effectively identified.

Keywords: Lithium-ion battery; internal short-circuit fault; fault diagnosis; variational mode decomposition (VMD); random forest (RF)

收稿日期：2023-11-20；**修回日期**：2024-01-09；**录用日期**：2024-01-12；**网络首发日期**：2024-04-26
基金项目：国家自然科学基金资助项目(52167004)；宁夏回族自治区智能装备与精密检测技术研究应用创新团队资助项目(2022BSB03104)；北方民族大学创新项目(YCX23135)
This work is supported by National Natural Science Foundation of China under the grant 52167004; Ningxia Hui Autonomous Region Intelligent Equipment and Precision Detection Technology Research and Application Innovation Team under the grant 2022BSB03104; North Minzu University Innovation Project under the grant YCX23135

随着能源危机与环境污染问题的出现，各国开始减少一次性能源的使用，增加可再生能源的使用比重。风能、水能等可再生能源储量丰富，已成为全球替代一次能源的焦点。然而可再生能源具有不稳定的特点，要使其得到充分利用，需要存储剩余能量的设备来存储电力。在电力系统中，储能设备可以调节电能的供需关系。对于新能源汽车，储能设备为其提供动力，直接关系到新能源汽车的

安全及相关性能问题。因此，对储能设备是否存在故障进行深入研究，不仅有利于电力系统与新能源汽车的安全可靠运行，而且有助于可再生能源的推广应用，加快解决各国能源危机、环境污染的问题。

锂离子电池具有使用寿命长、能量密度高、成本低等特点，在储能系统中被广泛应用[1]；但在使用过程中电池内部会发生非常复杂的化学反应，致使其安全问题一直堪忧[2-4]。

电池老化引发的渐变性故障[5]与电池组突然发生失效引发的突发性故障[6]是锂离子电池在应用过程中的主要故障类型。其中，由内短路引发热失控即为突发性故障的一种[7]。突发性故障是指突然发生、难以预测的故障，通常危害极大[8]。文献[9]提出基于一阶等效电路模型的电池外部短路故障诊断方法；文献[10]提出基于改进残差网络的锂离子电池故障诊断方法；文献[11]提出基于等效电路模型的方法，该方法通过对正常电池和故障电池的电压进行参数辨识，实现故障诊断；文献[12]提出基于电压相关系数的电池短路故障检测方法。

针对锂离子电池在实际使用过程中引发的内短路故障，并伴随热失控，甚至导致电池爆炸事故发生的问题，本文采用了基于麻雀搜索算法优化变分模态分解 SSA-VMD(sparrow search algorithm optimized variational mode decomposition)与随机森林 RF(random forest)算法的故障诊断方法。首先，利用 SSA 对 VMD 分解的重要参数惩罚因子 α 与分解层数 K 进行寻优；接着，计算信号经 VMD 分解得出的模态分量 IMF(intrinsic mode function)的样本熵值；最后，将样本熵值作为特征向量输入 RF 模型中，诊断内短路故障[13]。由最终结果可知，在锂离子电池出现故障时，诊断模型能够准确识别故障。

1 基本原理

1.1 变分模态分解

VMD 是一种信号处理方法，对信号处理具有良好的效果，它可以克服集合经验模态分解 EEMD (ensemble empirical mode decomposition)在处理信号时存在的模态混叠现象，提高故障的诊断率[13-14]。

设初始信号 f 由模态分量 $u_k(t)$ 组成。首先通过希尔伯特变换求得 $u_k(t)$ 的单边频谱；然后经过中心频率 ω_k，将其频谱调制到基频带；最后计算得到 $u_k(t)$ 的带宽，对应约束条件为

$$\begin{cases}\min\limits_{\{u_k\},\{\omega_k\}}\left\{\sum\limits_k\left\|\partial_t\left[\left(\delta(t)+\dfrac{\mathrm{j}}{\pi t}\right)*u_k(t)\right]\mathrm{e}^{-\mathrm{j}\omega_k t}\right\|_2^2\right\}\\ \text{s.t.}\sum\limits_k u_k(t)=f\end{cases}\tag{1}$$

式中：k 为预设的分解模态数；∂_t 为梯度运算；$\delta(t)$ 为狄拉克函数；*为卷积运算[13]。

变分模型计算过程如下。

(1)在式(1)中引入惩罚因子 α 与拉格朗日算子 $\lambda(t)$，则式(1)变为非约束性问题，其表达式为

$$\begin{aligned}L(\{u_k\},\{\omega_k\},\lambda)=&\left\langle\lambda(t),x(t)-\sum_k u_k(t)\right\rangle+\\&\left\|f(t)-\sum_k u_k(t)\right\|_2^2+\\&\alpha\sum_k\left\|\partial_t\left[\left(\delta(t)+\frac{\mathrm{j}}{\pi t}\right)*u_k(t)\right]\mathrm{e}^{-\mathrm{j}\omega_k t}\right\|_2^2\end{aligned}\tag{2}$$

式中：$L(\{u_k\},\{\omega_k\},\lambda)$ 为增广拉格朗日函数；u_k 为第 k 个信号分量的集合；$x(t)$ 为辅助变量/参考信号；〈 〉为内积运算。

(2)依据式(2)对 u_k、ω_k 和 λ 进行累次迭代并修正，找到最终优解。通过帕塞瓦尔定理寻找 u_k^{n+1} 在频域上的表达式 $\hat{u}_k^{n+1}(\omega)$，其中，n 为累计迭代发生次数。初始化 $\{\hat{u}_k^1(\omega)\}$、$\{\hat{\omega}_k^1(\omega)\}$ 和 $\hat{\lambda}^1(\omega)$，其中，$\{\hat{u}_k^1(\omega)\}$、$\{\hat{\omega}_k^1(\omega)\}$ 分别为第 1 次迭代时，所有模态分量的频域形式、中心频率的初始值集合；$\hat{\lambda}^1(\omega)$ 为第 1 次迭代时，频域下的拉格朗日乘子的初始值。更新 $\hat{u}_k^{n+1}(\omega)$、$\{\hat{\omega}_k^{n+1}(\omega)\}$ 和 $\hat{\lambda}^{n+1}(\omega)$ 的表达式分别为

$$\hat{u}_k^{n+1}(\omega)=\frac{\hat{f}(\omega)-\sum\limits_{i<k}\hat{u}_i^{n+1}(\omega)-\sum\limits_{i>k}\hat{u}_i^{n}(\omega)+\dfrac{\hat{\lambda}^n(\omega)}{2}}{1+2\alpha(\omega-\omega_k^n)^2}\tag{3}$$

$$\hat{\omega}_k^{n+1}(\omega)=\frac{\int_0^{\infty}\omega\left|\hat{u}_k^{n+1}(\omega)\right|^2\mathrm{d}\omega}{\int_0^{\infty}\left|\hat{u}_k^{n+1}(\omega)\right|^2\mathrm{d}\omega} \tag{4}$$

$$\hat{\lambda}^{n+1}(\omega)=\hat{\lambda}^{n}(\omega)+\tau(\hat{f}(\omega))-\sum_k\hat{u}_k^{n+1}(\omega) \tag{5}$$

式中：$\hat{u}_k^{n+1}(\omega)$、$\{\hat{\omega}_k^{n+1}(\omega)\}$分别为第 n+1 次迭代更新后，第 k 个模态分量对应的频域形式、中心频率；$\hat{\lambda}^{n+1}(\omega)$为第 n+1 次迭代更新后，频域下的拉格朗日乘子；τ为带宽。

迭代的最终停止条件为

$$\sum_k\frac{\left\|\hat{u}_k^{n+1}(\omega)-\hat{u}_k^{n}(\omega)\right\|_2^2}{\left\|\hat{u}_k^{n+1}(\omega)\right\|_2^2}<\varepsilon \tag{6}$$

式中，ε为判别精度且其值大于 0。

VMD 是 1 种新兴的信号处理算法，其本身具有严密的数学基础，能够有效解决信号分解产生的模态混叠现象，在非平稳、非线性信号的频谱分析中展现出优异的分解性能；但该算法对参数具有强依赖性，其分解效果依赖于参数的选取。本文以 VMD 理论为基础，对算法中的参数选取进行寻优。

1.2 基于 SSA-VMD 构建特征向量

在 VMD 算法中有 2 个参数的取值至关重要，分别是惩罚因子 α 与分解层数 K。若 α 取值较大会缺失信号中附带的信息，反之则产生较多的无用信号；若 K 值过大会产生信号过度分解的现象，反之则会产生信号未完全分解的现象。因此，α 与 K 的取值至关重要。本文选择 SSA 算法优化 VMD 参数，将包络熵极小值作为适应度函数寻优目标。

在 SSA 算法中，麻雀被分为发现者、加入者、警戒者。在无约束条件下，麻雀与麻雀间会互相监视，加入者通过抢夺其他麻雀食物提高自己的捕食率。觅食时，所有个体保持警惕预防天敌。

种群 $\boldsymbol{X}$ 由 n 只麻雀组成，表示为

$$\boldsymbol{X}=\begin{bmatrix}x_1^1 & x_1^2 & \cdots & x_1^d\\ x_2^1 & x_2^2 & \cdots & x_2^d\\ \vdots & \vdots & \vdots & \vdots\\ x_n^1 & x_n^2 & \cdots & x_n^d\end{bmatrix} \tag{7}$$

式中：d 为待优化问题的维数；n 为麻雀的数量；x_n^d 为第 n 个麻雀个体在第 d 维优化变量上的位置取值。种群的适应度值为

$$\boldsymbol{F}_x=\begin{bmatrix}f\left[x_1^1 & x_1^2 & \cdots & x_1^d\right]\\ f\left[x_2^1 & x_2^2 & \cdots & x_2^d\right]\\ & \vdots & & \\ f\left[x_n^1 & x_n^2 & \cdots & x_n^d\right]\end{bmatrix} \tag{8}$$

在搜索中，发现者在觅食过程中，有获取食物的优先权，在种群中它们指挥行动方向、寻找食物。因此发现者觅食时，搜索范围最广。依据式(7)~式(8)，发现者位置迭代更新表达式为

$$X_{i,j}^{t+1}=\begin{cases}X_{i,j}^{t+1}\cdot\mathrm{e}^{\frac{-i}{\alpha\cdot\mathrm{iter}_{\max}}} & R_2<S_{\mathrm{ST}}\\ X_{i,j}^{t+1}+Q\cdot\boldsymbol{L} & R_2\geqslant S_{\mathrm{ST}}\end{cases} \tag{9}$$

式中：t 为迭代次数；j=1, 2,⋯, d；$X_{i,j}$为 d 维中麻雀 i 的位置；$\mathrm{iter}_{\max}$为迭代次数的最大值；R_2为警报值；S_{ST}为稳定值；Q 为服从正态分布的随机数；$\boldsymbol{L}$ 为 1×d 的矩阵。当稳定值>警报值时，表示此时安全，发现者可扩大搜索范围；当稳定值≤警报值时，表示此时有捕食者，警戒者进行警报，麻雀迅速逃到安全的地方进行觅食。

对于新加入的麻雀，依据式(9)，当加入者察觉到发现者找到食物时，加入者会与之争夺。在争夺时，若加入者获胜则加入者取得食物；否则更新加入者位置，表达式为

$$X_{i,j}^{t+1}=\begin{cases}Q\cdot\mathrm{e}^{\frac{X_{\mathrm{worst}}-X_{i,j}^{t}}{\alpha\cdot\mathrm{iter}_{\max}}} & i>\dfrac{n}{2}\\ X_{\mathrm{p}}^{t+1}+\left|X_{i,j}-X_{\mathrm{p}}^{t+1}\right|\cdot\boldsymbol{A}^{+}\cdot\boldsymbol{L} & \text{其他}\end{cases} \tag{10}$$

式中：X_{worst}为最差发现者位置；X_{p}为最优发现者位置；$\boldsymbol{A}^{+}=\boldsymbol{A}^{\mathrm{T}}(\boldsymbol{A}\boldsymbol{A}^{\mathrm{T}})^{-1}$，$\boldsymbol{A}$ 为元素为 1 或−1 的 1×d 矩阵。当 i>n/2 时，加入者 i 因为适应度值低，没有食物。

当有 10%的麻雀认为此刻有危险时，其位置更新表达式为

$$X_{i,j}^{t+1}=\begin{cases}X_{\mathrm{best}}^{t}+\beta\cdot\left|X_{i,j}^{t}-X_{\mathrm{best}}^{t}\right| & f_i>f_{\mathrm{g}}\\ X_{i,j}^{t}+K\cdot\left(\dfrac{\left|X_{i,j}^{t}-X_{\mathrm{worst}}^{t}\right|}{(f_i-f_{\mathrm{w}})+\varepsilon}\right) & f_i=f_{\mathrm{g}}\end{cases} \tag{11}$$

式中：X_{best} 为最优位置；β 为服从(0, 1)正态分布的随机步长控制因子，用于平衡算法的全局搜索与局部开发能力；f_i 为个体适应度值；f_g 为全局最佳值；K 为[−1, 1]的随机数；f_w 为最差适应度值。当个体适应度值>全局最佳值时，表示该麻雀极易遭遇危险，处在种群最边缘；当个体适应度值=全局最佳值时，表示有危险，种群需要聚拢以降低捕食风险。SSA-VMD 的流程如图 1 所示。

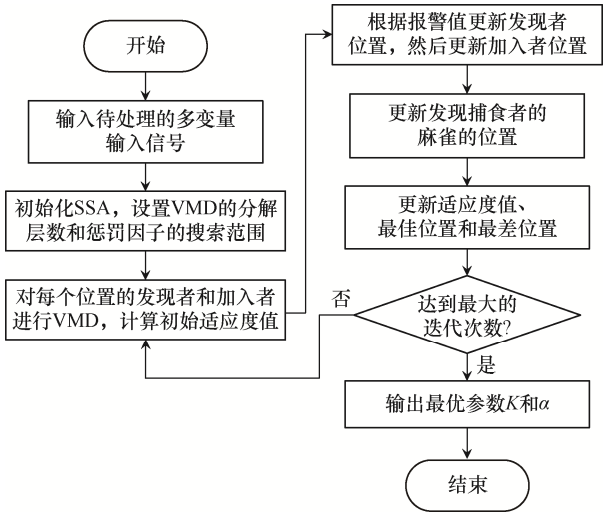


图 1 SSA-VMD 流程

Fig. 1 Flow chart of SSA-VMD

1.3 样本熵

样本熵的优势在于不需要与自己相比，误差较小、一致性好、抗干扰能力强。正常状态运行时，锂离子电池的电压信号波动较小；发生故障时，其电压信号在一段时间内骤降并快速恢复正常。由于信息熵在计算时需要大量数据，当信号很复杂、波动很小时，信息熵的表现不是非常理想，可能会产生误差。因此，本文选择样本熵作为 RF 的输入特征，主要用于分解锂离子电池内短路故障电压信号，并将其用于故障分类的输入。对任一输入的时间序列 $x(i)$，i=1, 2, ⋯, N，其样本熵的计算步骤如下：

(1)构建维数为 m 的时间序列向量 $\boldsymbol{X}(i)$={$x(i)$, $x(i+1)$, ⋯, $x(i+m-1)$}，其中，$1\leqslant i\leqslant M-m+1$；

(2)计算向量 $\boldsymbol{X}(i)$与 $\boldsymbol{X}(j)$之间的最大距离 $d(i,j)$，并将其定义为 $d(i,j)=\max\{|x(i+k-1)-x(j+k-1)|\}$，其中，$k$=1, 2, ⋯, m、$i\geqslant 1$、$j\leqslant M-m+1$、$i\neq j$；

(3)设定参数相似容度 r，计算 B_i 与向量总数 $N-m$ 之比，将其定义为 $B_i^m(r)$，并求出 $N-m+1$ 个 $B_i^m(r)$ 的平均值，将其定义为 $B^m(r)$，表达式为

$$B^m(r)=\frac{1}{N-m+1}\sum_{i=1}^{N-m+1}B_i^m(r) \tag{12}$$

(4)将向量维数增大到 m+1，然后重复(1)~(3)，获得 $B^{m+1}(r)$；

(5)根据(3)中设定的 r，计算具有 m 嵌入维度的样本熵,其表达式为

$$S_{\mathrm{SampEn}}(m,r)=\lim_{N\to\infty}\left\{-\ln\left[\frac{B^{m+1}(r)}{B^m(r)}\right]\right\} \tag{13}$$

定义时间序列 N 为有限值，估算样本熵的表达式为

$$S_{\mathrm{SampEn}}(m,r,N)=-\ln\left[\frac{B^{m+1}(r)}{B^m(r)}\right] \tag{14}$$

式中：$B^{m+1}(r)$为 2 个序列匹配 m+1 个点的概率；$B^m(r)$为 2 个序列匹配 m 个点的概率。

1.4 随机森林

RF 在建立过程中采取随机的方式，且 RF 由许多决策树构成，决策树与决策树之间并无关联。RF 完成建立后，当有新样本数据输入时，所有决策树同时工作将输入样本进行划分，然后根据划分结果预测样本类型。

决策树建立时，需要采用随机采样与完全分裂的方式。首先是 2 个随机采样，RF 采取有放回的采样方式。该采样方式使得样本中有重复样本。例如，输入样本为 N 个，则采样样本也为 N 个。这使得在训练时，决策树与决策树输入的样本都不是所有样本，避免了过度拟合(over-fitting)。然后列采样，从 M 个特征中，选择 m 个。接着建立决策树，采用完全分裂的方式对采样后的数据进行处理，这使得决策树的子节点分裂彻底。此外，2 个随机采样的过程保证了随机性，很大程度避免了过度拟合。

RF 算法能够较好地处理分类和回归问题，其诊断准确率极高，能够有效地在大数据集上运行。同时，RF 算法引入了随机性，不容易过拟合。此外，它不仅能处理离散型数据，还能处理连续型数据。

但当 RF 算法中的决策树数量较多时，训练所需的空间和时间开销较大，这将导致模型诊断速度变慢。

1.5 锂离子电池故障诊断流程

锂离子电池内短路故障诊断流程如图 2 所示。首先进行 VMD 分解，将锂离子电池电压信号作为输入，经过 VMD 分解得到 IMF 分量，计算分解后每个 IMF 的样本熵；接着将样本熵值作为特征向量输入；然后把输入的特征向量随机分成测试集和训练集；最后将随机分组的特征向量分别输入到 SVM 模型与 RF 模型中进行训练与诊断[13]。

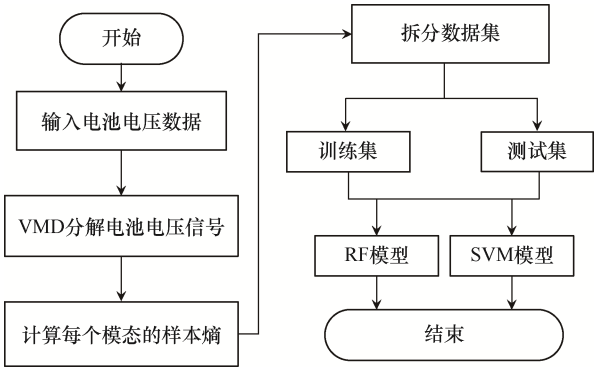


图 2　锂离子电池内短路故障诊断流程

Fig. 2 Flow chart of lithium-ion battery internal short-circuit fault diagnosis

2　实验验证及仿真结果分析

2.1 信号获取

实验平台由充放电系统与上位机构成，如图 3 所示。充放电系统采用型号 CT-4008T-5V6A 的 8 通道仪器，实现对锂离子电池电压、电流数据的采集。

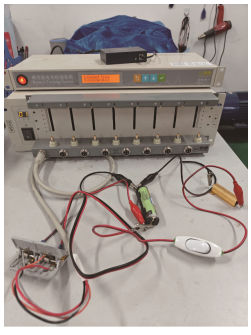


图 3　实验平台

Fig. 3 Experimental platform

通过模拟电池故障，并对比其与正常锂离子电池，发现锂离子电池在发生内短路故障后，由于内阻增加导致电压有一段时间的突降，并在一段时间后恢复至正常，因此本文选择锂离子电池的电压作为输入信号。将锂离子电池与电阻并联，通过开关控制，模拟内短路故障的发生，并获得故障信号，等效电路如图 4 所示。其中，实验选取 R_{TSC} 的阻值为 0.5 Ω。

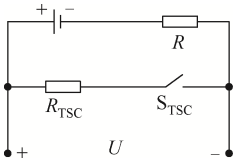
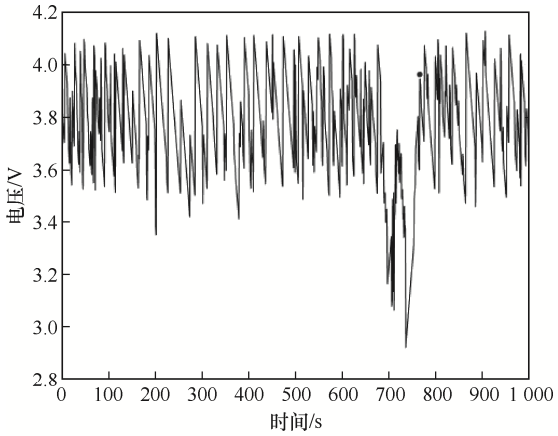


图 4　内短路实验等效电路

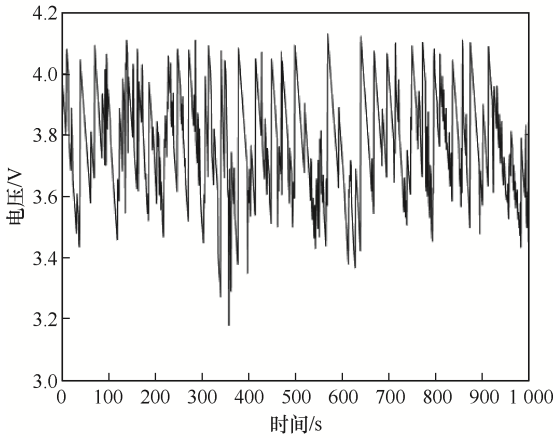
Fig. 4 Equivalent circuit under internal short-circuit fault

2.2 信号处理

实验所用电池为三元锂离子电池，最高电压为 4.2 V、截止最低电压为 2.5 V；实验截取数据为 1 000。图 5(a)、(b)分别为发生故障与正常状态 2



(a) 故障



(b) 正常

图 5　电压信号

Fig. 5 Voltage signals

种电压信号。

在进行信号分解时，分解层数 K 和惩罚因子 α 的值至关重要。随机选取 1 组故障信号，设麻雀种群数量为 20、迭代次数为 50、K 为[5,14]的整数、α 为[100, 2 600]的整数。图 6 为 SSA-VMD 收敛曲线。由图可知，在第 15 次迭代取得最优参数 K=10、α=2 000，此时适应度值为 0.037 228。当 K 和 α 的值最优时，VMD 分解及其频谱如图 7 所示，其中 S 为原始信号。

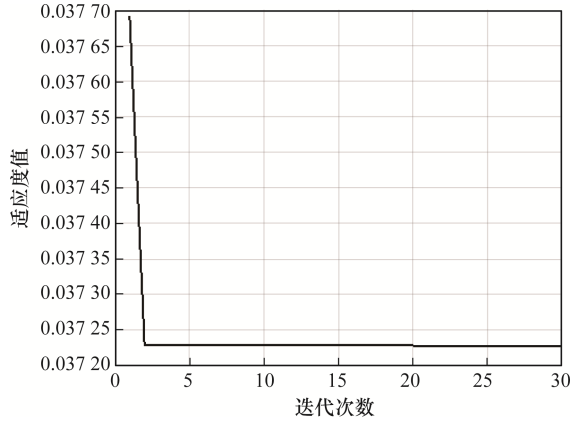
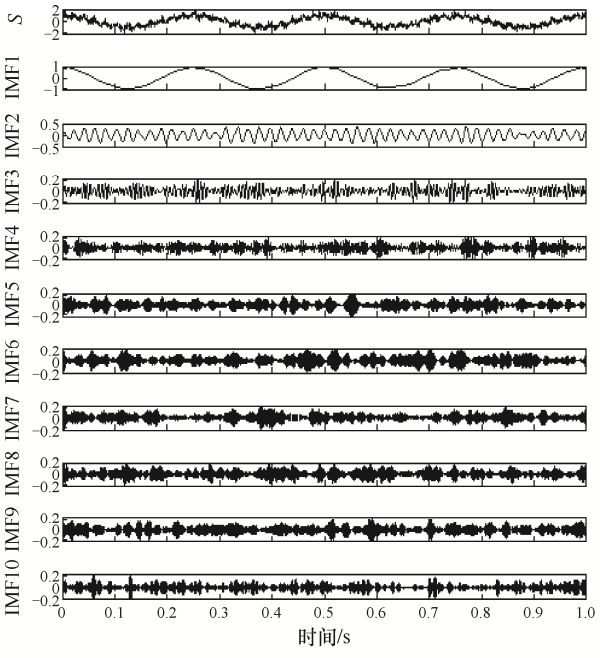


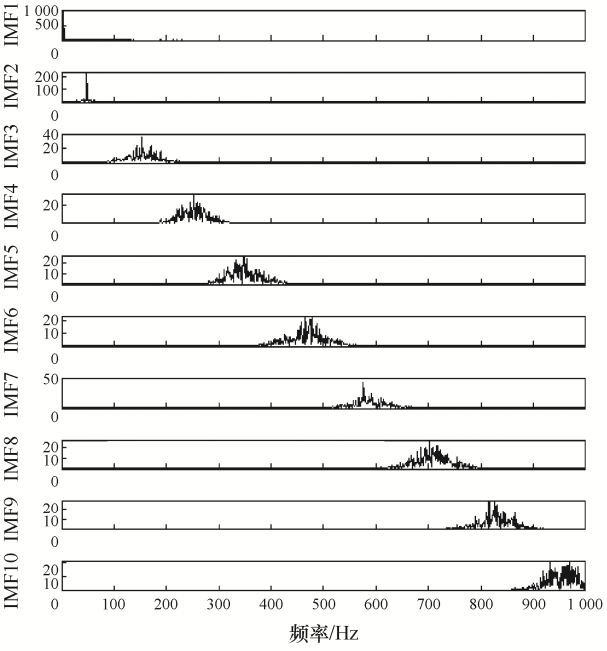
图 6 SSA-VMD 收敛曲线

Fig. 6 SSA-VMD convergence curve

为验证分解算法的优势，将信号同时进行 EEMD 分解，结果如图 8 所示。由图可知，EEMD



(a) VMD分解



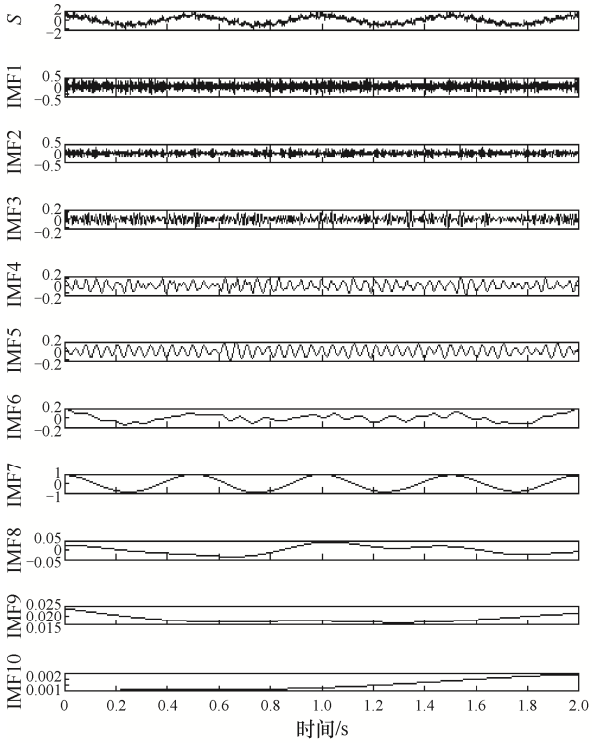
(b) VMD分量频谱

图 7 故障信号 VMD 分解

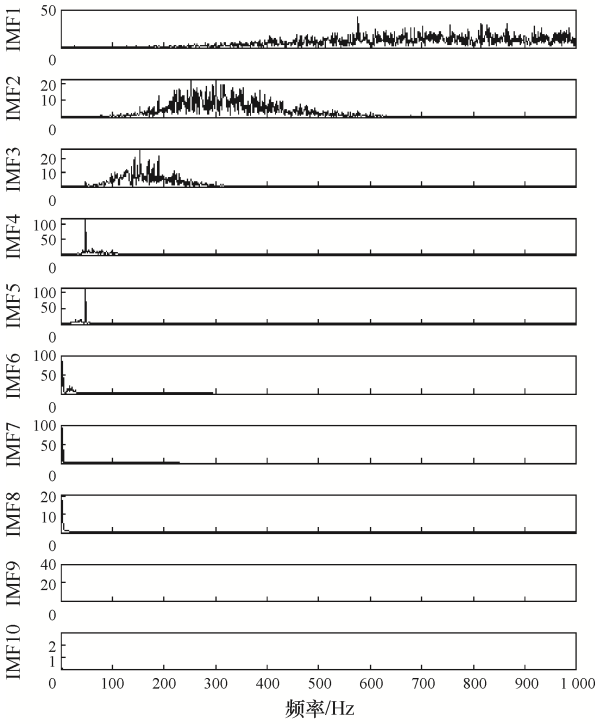
Fig. 7 VMD decomposition of fault signal

分解效果微弱于 VMD 分解。这是由于在信号分解时发生了模态混叠，未获取全部信号特征。

综上可得，VMD 在信号分解方面避免了 EEMD 在分解时产生的模态混叠现象，比 EEMD



(a) EEMD分解



(b) EEMD分量频谱

图 8　故障信号 EEMD 分解

Fig. 8 EEMD decomposition of fault signals

分解更具优势，为故障识别提供了更加可靠的信号特征。

2.3　特征提取

对信号分解的各 IMF 计算得出样本熵，通过样本熵值识别锂离子电池故障。对正常信号与故障信号同时进行 VMD 分解，并计算分解后各 IMF 的样本熵，随后将样本熵值输入到 RF 模型中。图 9 为 2 种信号样本熵值的分解对比。由图可知，在 IMF2 与 IMF4 之间，样本熵值有较大差别，故样本熵值可作为故障诊断的判别依据之一。

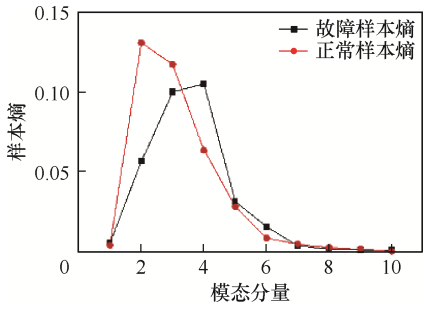


图 9　锂离子电池故障与正常电压的熵值分解对比

Fig. 9 Comparison between decomposed entropy values of fault and normal voltages for lithium-ion battery

2.4　故障诊断

首先，分别选取 30 组正常状态和故障状态的数据；接着，从 30 组正常状态数据中选取 15 组、从 30 组故障状态数据中选取 15 组，作为 RF 与 SVM 模型的训练集；最后，将剩余的 30 组数据作为 RF 与 SVM 模型的测试集。

本文采用 MATLAB 编程语言构建 SVM 与 RF 模型；采取标签方式表示锂离子电池的 2 种状态，正常状态为 1、故障状态为 2。将测试集数据输入到训练好的 SVM 和 RF 模型中，得到的分类结果如图 10~图 11 所示。

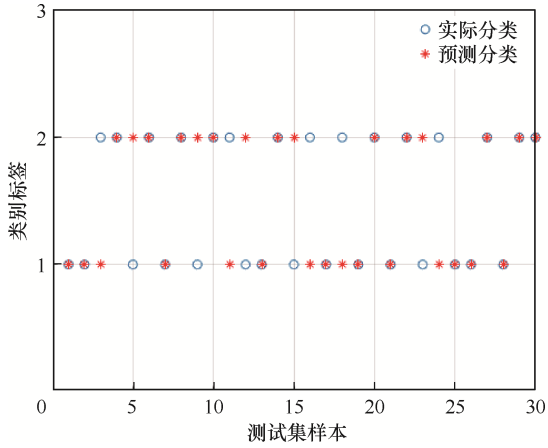


图 10　SVM 故障分类

Fig. 10 SVM fault classification

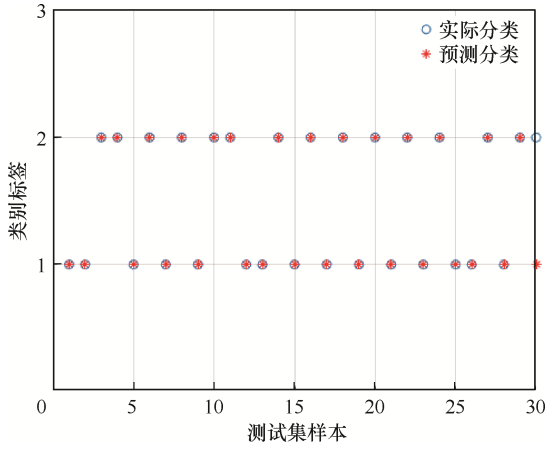


图 11　RF 故障分类

Fig. 11 RF fault classification

对比 2 种模型的分类结果可知，RF 模型仅有 1 个样本被分错，SVM 的故障诊断准确率<RF 的诊断准确率，2 种模型的故障诊断结果见表 1。由

表可知，RF 诊断精度较高，具有良好的诊断效果。因此本文采用基于 RF 的诊断算法。

表 1 诊断结果

Tab. 1 Diagnostic results

诊断方法	识别率/%
SVM	66.667 0
RF	96.666 7

为验证诊断算法的可靠性，分别并联 0.5、2.0、5.0 Ω 电阻模拟不同程度的内短路故障，获取不同程度的内短路故障信号。经过故障诊断模型的诊断，锂离子电池内短路故障得到了有效识别，其诊断结果见表 2。

表 2 不同程度内短路故障诊断结果

Tab. 2 Diagnosis results of internal short-circuit faults with different degrees

并联电阻/Ω	诊断率/%
0.5	96.666 7
2.0	96.466 7
5.0	95.735 0

3 结论

本文提出基于 SSA-VMD 和 RF 的锂离子电池内短路故障诊断算法。由诊断结果可知，该方法在信号处理时高效、故障识别诊断率较高。同时得出以下结论。

(1)在信号分解时，将 VMD 分解与 EEMD 分解进行对比分析，结果表明 VMD 分解能够克服 EEMD 在分解时产生的模态混叠现象。

(2)参数对 VMD 分解至关重要。通过 SSA 算法对 K 和 α 进行寻优，寻得最优参数组合[K, α]，分解出的 IMF 分量可作为 RF 的特征输入向量。

(3)将 RF 模型与 SVM 模型进行对比分析，结果表明基于 RF 模型的故障诊断准确率更高。

(4)通过模拟不同程度的内短路故障，验证了该模型可有效识别内短路故障，展现了模型的可靠性。

参考文献：

[1] 赵沁峰, 蔡艳平, 王新军. 锂离子电池全生命周期剩余使用寿命预测[J]. 电源学报, 2024, 22(2): 197-204.
Zhao Qinfeng, Cai Yanping, Wang Xinjun. Remaining useful life prediction for full life cycle of lithium-ion battery [J]. Journal of Power Supply, 2024, 22(2): 197-204. (in Chinese)

[2] 孙静, 翟千淳. 基于融合特征和 OOA-BiGRU 的锂离子电池剩余使用寿命预测方法[J]. 电工技术学报, 2025, 40(9): 2996-3012.
Sun Jing, Zhai Qianchun. A novel remaining useful life prediction method based on fusion feature and OOA-BiGRU for lithium-ion batteries [J]. Transactions of China Electrotechnical Society, 2025, 40(9): 2996-3012. (in Chinese)

[3] 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, 6344.
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, 6344. (in Chinese)

[4] 孙振宇, 王震坡, 刘鹏, 等. 新能源汽车动力电池系统故障诊断研究综述[J]. 机械工程学报, 2021, 57(14): 87-104.
Sun Zhenyu, Wang Zhenpo, Liu Peng, et al. Overview of fault diagnosis in new energy vehicle power battery system [J]. Journal of Mechanical Engineering, 2021, 57(14): 87-104. (in Chinese)

[5] 张从佳, 施敏达, 徐晨, 等. 基于动态可重构电池网络的储能系统本质安全机制及实例分析[J]. 储能科学与技术, 2022, 11(8): 2442-2451.
Zhang Congjia, Shi Minda, Xu Chen, et al. Intrinsic safety mechanism and case analysis of energy storage systems based on dynamically reconfigurable battery network [J]. Energy Storage Science and Technology, 2022, 11(8): 2442-2451. (in Chinese)

[6] 刘宏阳, 杨林, 李济霖. 基于长短期记忆网络的电动汽车电池故障诊断[J]. 机电一体化, 2020, 26(Z1):

17-23, 37.
Liu Hongyang, Yang Lin, Li Jilin. Fault diagnosis of electric vehicle battery based on long short-term memory network [J]. Mechatronics, 2020, 26(Z1): 17-23, 37. (in Chinese)

[7] 山彤欣, 王震坡, 洪吉超, 等. 新能源汽车动力电池“机械滥用-热失控”及其安全防控技术综述[J]. 机械工程学报, 2022, 58(14): 252-275.
Shan Tongxin, Wang Zhenpo, Hong Jichao, et al. Overview of “mechanical abuse-thermal runaway” of electric vehicle power battery and its safety prevention and control technology [J]. Journal of Mechanical Engineering, 2022, 58(14): 252-275. (in Chinese)

[8] 苏伟, 钟国彬, 沈佳妮, 等. 锂离子电池故障诊断技术进展[J]. 储能科学与技术, 2019, 8(2): 225-236.
Su Wei, Zhong Guobin, Shen Jiani, et al. The progress in fault diagnosis techniques for lithium-ion batteries [J]. Energy Storage Science and Technology, 2019, 8(2): 225-236. (in Chinese)

[9] Chen Zeyu, Xiong Rui, Tian Jinpeng, 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.

[10] 段双明, 徐超. 基于改进残差网络的锂离子电池故障诊断[J]. 电池, 2023, 53(3): 257-261.
Duan Shuangming, Xu Chao. Fault diagnosis of Li-ion battery based on improved residual network [J]. Battery Bimonthly, 2023, 53(3): 257-261. (in Chinese)

[11] Feng Xuning, Weng Caihao, Ouyang Minggao, et al. Online internal short circuit detection for a large format lithium ion battery [J]. Applied Energy, 2016, 161: 168-180.

[12] Xia Bing, Shang Yunlong, Nguyen T, et al. A correlation based fault detection method for short circuits in battery packs [J]. Journal of Power Sources, 2017, 337: 1-10.

[13] 王君瑞, 吴新举, 赵东琦, 等. 基于 WOA-VMD 与 PSO-SVM 的锂离子电池内短路故障诊断方法[J]. 工程科学学报, 2023, 45(12): 2162-2172.
Wang Junrui, Wu Xinju, Zhao Dongqi, et al. Research on internal short-circuit fault diagnosis methods for lithium-ion batteries based on WOA-VMD and PSO-SVM [J]. Chinese Journal of Engineering, 2023, 45(12): 2162-2172. (in Chinese)

[14] 丁恒, 黄凯, 田海建. 基于 VMD 和 ISSA-ELM 的锂离子电池剩余使用寿命预测[J]. 电源学报, 2024, 22(6): 188-198.
Ding Heng, Huang Kai, Tian Haijian. Prediction of remaining useful life of lithium-ion battery based on VMD and ISSA-ELM [J]. Journal of Power Supply, 2024, 22(6): 188-198. (in Chinese)



王君瑞

作者简介：

王君瑞(1978—)，女，通信作者，博士，教授。研究方向：新能源发电技术，微网控制及电机控制技术。E-mail：jr09110111@163.com。

季长江(1998—)，男，中国电源学会学生会员，硕士研究生。研究方向：锂离子电池安全管理。E-mail：j18831402576@163.com。

李进(1998—)，男，硕士研究生。研究方向：锂离子电池 SOC 估算。E-mail：l18726742621@163.com。

谭露(1999—)，男，硕士研究生。研究方向：新能源与电力电子技术。E-mail：3132318365@qq.com。

朱旭强(1998—)，男，硕士研究生。研究方向：新能源与电力电子技术。E-mail：13419705643@163.com。

(责任编辑：耿越)