

基于 WOA-VMD 与 PSO-SVM 的锂离子电池内短路故障诊断方法

王君瑞✉, 吴新举, 赵东琦, 王丽宝, 代 丽, 白冰超

北方民族大学电气信息工程学院, 银川 750021
✉通信作者, E-mail: jr09110111@163.com

摘 要 为了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热失控现象, 提出了鲸鱼优化算法优化变分模态分解(WOA-VMD)和粒子群算法优化支持向量机(PSO-SVM)的故障诊断方法. 首先通过 WOA 寻找 VMD 分解层数 K 和惩罚因子 α 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; 其次, 计算各模态分量(IMF)的样本熵值作为特征向量; 最后将特征向量分别输入至 SVM 故障诊断模型与 PSO-SVM 故障诊断模型中进行故障诊断. 结果表明, SVM 故障诊断率 66.667%, 经 PSO 优化过的 SVM 故障诊断率为 96.667%, 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; 支持向量机

分类号 TM912

Research on internal short-circuit fault diagnosis methods for lithium-ion batteries based on WOA-VMD and PSO-SVM

WANG Junrui✉, WU Xinju, ZHAO Dongqi, WANG Libao, DAI Li, BAI Bingchao

School of Electrical Information Engineering, North Minzu Univesity, Yinchuan 750021, China
✉Corresponding author, E-mail: jr09110111@163.com

ABSTRACT With the continuous consumption of traditional fossil fuels, people have gradually started to realize the importance of protecting the environment. Therefore, new clean energy sources like wind power have been gradually receiving considerable attention in recent years, along with the rapid development of new energy vehicles as replacements for traditional cars. Lithium-ion batteries have emerged as essential energy storage equipment for clean energy systems and power sources of new energy vehicles. However, these batteries are prone to thermal runaway failure during their usage and pose safety concerns. To ensure the safe operation of energy storage equipment and new energy vehicles, this paper proposes fault diagnosis methods using whale optimization algorithm optimized variational mode decomposition (WOA-VMD) and particle swarm optimization support vector machine (PSO-SVM) for diagnosing internal short-circuit fault voltage signals of lithium batteries, as they cause runaway heating. First, the internal short-circuit fault voltage signal in the lithium battery is decomposed using VMD to obtain a series of natural mode components. Two parameters in the VMD algorithm that significantly impact the decomposition results include the number of decomposition layers K and penalty factor α . To achieve the best decomposition effect, WOA was used to determine the VMD optimal decomposition level K and penalty factor α . Further, the optimal parameter combination is found to be $K = 10$ and $\alpha = 1997$. Subsequently, this optimal parameter combination was introduced into VMD decomposition to decompose the internal short-circuit fault signal of the lithium-ion battery to obtain 10 modal

components. Thus, the sample entropy of each of the 10 modal components was calculated and used as the eigenvector. Finally, these eigenvectors were inputted into the SVM model, and then the PSO-optimized SVM model was used for fault diagnosis, providing the diagnostic results. The final results showed that the diagnostic accuracy of the direct SVM model remained stable at 66.667%, while the diagnostic accuracy of the PSO-optimized SVM model was stable at 96.667%. Compared with the direct SVM model, the PSO-SVM diagnostic model effectively identified the internal short-circuit fault of the lithium-ion battery in the SVM model after feature selection by the particle swarm optimization algorithm, thereby proving its effectiveness.

KEY WORDS lithium-ion battery; internal short-circuit fault; fault diagnosis; variational modal decomposition; support vector machines

锂离子电池具有长寿命, 高能量密度, 低自放电率, 低成本等特点, 被广泛应用为电力系统中的储能设备^[1]. 但由于锂离子电池本身在运行时涉及到复杂的电化学反应, 其安全问题无法得到保证^[2]. 在实际运行过程中, 锂离子电池可能会发生过充、过放、过热等现象, 进而造成锂离子电池性能衰退, 甚至发生内短路故障引发电池热失控^[3]. 在储能系统中, 经常将大量单体电池用连接组件通过串并联方式组成电池组与电池包, 电池系统的复杂程度也随之增加, 这就导致发生各类故障的概率增大, 增加了储能系统中的安全隐患^[4-5].

锂离子电池本体实际运行中出现的故障主要分为两类: 渐变性和突发性故障^[6]. 渐变故障主要由使用时间过长电池老化导致^[7]. 突发性故障是指无明显特征, 使得电池组突然失效的故障, 包括内短路引发的热失控故障与锂离子电池漏液等^[8-9]. 突发性故障相对于渐变故障发生时没有明显特征, 时间更短, 潜在危害更大, 是锂离子电池本体故障诊断中急需解决的难点^[10]. 锂电池的内短路故障诊断难点在于其潜伏期长、隐蔽性强.

目前, 锂离子电池故障诊断方法主要分为两种, 分别是基于电池模型的故障诊断方法与无电池模型的故障诊断方法^[11]. 基于电池模型的方法可以准确描述正常和故障条件下电池状态的演变, 以此完成对电池故障的诊断^[12-13]. 文献[14]提出了一种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[15]提出了一种基于模型的在线内短路故障诊断算法, 该算法将测量的电压和温度转换为能够反映典型内部短路特征的固有电化学状态, 即容量过度耗尽和异常发热, 通过评估偏差来捕获电池内短路故障. 文献[16]提出了基于等效电路模型进行参数辨识的方法, 通过输入正常电池和故障电池的电压、电流参数就可以得到相对应的内阻辨识结果, 以此进行锂电池内短路故障的检测. 文献[17]提出了基于对称环路拓扑结构(SLCT)的方法用于检测锂电池内部短

路故障, SLCT 保证每块电池在电路中具有相同的优先级, 发生内短路故障时, 每个电池向内短路电池提供相同数量的短路电流, 内短路电池通过结合短路电流的比值与短路电流的特征来判断内短路故障是否发生.

然而, 基于电池模型的故障诊断方法通常有以下缺点: 第一, 对建模精度要求较高; 第二, 在许多研究中, 这些模型仅适用于某些类型的故障诊断; 第三, 难以设置合适的阈值^[18-19]. 无电池模型的故障诊断方法主要分为信号处理和机器学习的方法^[20]. 此类方法通过数据本身所携带的信息分析故障模式, 避免了复杂的模型, 建立数据模型来简化故障诊断过程. 文献[21]提出了一种基于状态表示方法的锂离子电池组故障诊断和热失控报警的数据驱动方法. 该方法不仅可以实现故障单元的准确识别和电压故障类型的准确确定, 而且可以实现故障的早期检测和热失控的早期预警. 文献[22]提出了一种基于电压曲线相关系数的锂离子电池短路故障检测方法. 文献[23]通过训练随机森林算法模型, 并对随机森林算法模型进行验证, 最终实验结果证明模型拥有高达 97% 的准确率.

针对锂电池发生内短路故障而引发的热失控故障进一步甚至会引发爆炸事故, 本文提出了基于鲸鱼优化算法优化变分模态分解(WOA-VMD)和粒子群算法优化支持向量机(PSO-SVM)的锂离子电池内短路故障诊断方法. 针对 VMD 分解层数 K 与惩罚因子 α 的选值, 本文利用 WOA 算法进行寻优; 然后, 将两种信号经 VMD 分解后的每个 IMF 分量的样本熵作为特征向量; 最后, 将样本熵构建的特征向量输入到 PSO-SVM 模型中, 以诊断锂离子电池内短路故障. 结果表明, 锂离子电池内短路故障得到了有效识别.

1 基本原理

1.1 变分模态分解(VMD)

VMD 是一种非递归信号变分分解算法, VMD

将输入信号分解为固定个数的模态分量, 能够有效解决经验模态分解 (EMD) 中存在的模态混叠、虚假分量等问题^[24].

假设某输入信号 f 为有限个模态分量 $u_k(t)$ 叠加而成, 首先利用希尔伯特变换计算出各模态分量 $u_k(t)$ 的单边频谱, 然后通过混合中心频率 ω_k , 调制 $u_k(t)$ 的频谱到基频带, 最终解得 $u_k(t)$ 的带宽, 则相应约束条件的变分模型如公式 (1) 所示:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right|_2^2 \right\} \\ \text{s.t. } \sum_k u_k(t) = f \end{cases} \quad (1)$$

式中, $\delta(t)$ 代表狄克拉函数, ∂_t 代表梯度运算, $*$ 表示卷积运算, j 是虚数单位, t 表示时间.

上述变分模型求解步骤如下:

1) 在公式 (1) 的基础上引入惩罚因子 α 和拉格朗日算子 $\lambda(t)$, 将公式 (1) 转化成非约束问题, 转化后的拉格朗日表达式如下所示:

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

式中, $\langle \rangle$ 表示内积运算.

2) 在上式基础上, 对 u_k , ω_k 和 λ 进行迭代修正, 寻找其鞍点, 即约束变分方程的最优解. 利用帕塞瓦尔定理得到 u_k^{n+1} 在频域上的表达式 $\hat{u}_k^{n+1}(\omega)$, 其中 n 为迭代次数.

初始化 $\hat{u}_k^1(\omega)$, $\hat{\omega}_k^1(\omega)$ 和 $\hat{\lambda}^1(\omega)$, 然后根据式 (3) ~ (5) 分别更新 $\hat{u}_k^{n+1}(\omega)$, $\hat{\omega}_k^{n+1}(\omega)$ 和 $\hat{\lambda}^{n+1}(\omega)$.

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

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

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

式中, τ 表示带宽.

最终迭代终止条件为:

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

式中, ε 为判别精度且大于 0.

VMD 分解中存在两个重要参数: 分解层数 K 和惩罚因子 α ^[25], 其对最终 VMD 分解结果影响较大, 因此通过 WOA 确定两参数的最优值.

1.2 基于鲸鱼优化变分模态分解 (WOA-VMD) 的特征向量构建

对于 VMD 分解算法中的两个重要参数: 分解层数 K 和惩罚因子 α , 如果 K 值过大, 就会产生过分解, 反之, 会产生欠分解; 如果 α 取值较大, 就会损坏频带信息, 相反, 较小就会导致信息冗杂, 因此需要确定最佳参数组合 $[K, \alpha]$. 当前常用的方法为中心频率观察法, 通过观察不同 K 值下的中心频率确定 K 值, 但是此方法具有偶然性, 仅能确定 K , 无法确定惩罚参数 α . 基于此, 本文选择 WOA 算法优化 VMD 参数组合 $[K, \alpha]$, 将包络熵极小值作为适应度函数.

鲸鱼优化算法 (WOA) 模拟对海洋中座头鲸的群体狩猎, 通过鲸鱼种群搜索、包围、捕获与攻击猎物的过程实现寻找最优结果. WOA 算法提供了包围猎物、螺旋气泡、寻找猎物的数学模型^[26]. 各个鲸鱼的初始位置代表一个可行解, 通过后期探索最终找到最佳位置, 即最优解.

如图 1 所示为 WOA 优化 VMD 参数的流程图. 首先对鲸群位置向量 $[K, \alpha]$ 进行初始化, 以包络熵值作为适应度函数, 接着计算各鲸鱼个体的适应度值, 最终根据收敛因子大小进行迭代公式的选择并反复迭代更新, 直到满足终止条件, 输出最佳 VMD 参数.

针对分解后的模态分量, 提出了样本熵 (Sample entropy, SE) 的量化方法, 熵值的大小与信号复杂度呈正比, 并且在不同的工作状态下, 信号对应的样本熵也有差异. 对于某个输入时间序列 $\{x(i), i=1, 2, \dots, N\}$, 当时间序列 N 为有限值时, 其样本熵的运算表达式为:

$$\text{SampEn}(m, r, N) = -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \quad (7)$$

式中: m 为嵌入维数; r 为相似容限; $B^m(r)$ 为两个时间序列在某固定相似容限下匹配 m 个点的概率; $B^{m+1}(r)$ 为两个时间序列在固定相似容限下匹配 $m+1$ 个点的概率.

选择合适的嵌入维数 m 取 1 或 2; 相似容限 r 取 0.1 ~ 0.2^[27]; 本文中参数取 $m=2, r=0.2$.




图1 WOA-VMD 流程图
Fig.1 Flow chart of WOA-VMD

1.3 粒子群算法优化支持向量机 (PSO-SVM)

SVM 的主要思想就是寻找一条直线将两类样本进行正确划分, 同时还要保证两类样本的分类间隔达到最大, 最终可转化成对式 (8) 所示的二次规划问题进行求解^[28].

$$\begin{cases} \min \frac{1}{2} (\omega \times \omega) + C \sum_{i=1}^n \varepsilon_i \\ \text{s.t. } y_i [(\omega \times x_i) + b] \geq 1 - \varepsilon_i, \varepsilon_i \geq 0, i = 1, \dots, n \end{cases} \quad (8)$$

式中, C 和 ε_i 分别表示惩罚参数和松弛变量. 将拉格朗日乘子 $\alpha_i (i=1, \dots, n)$ 引入式中, 就可以将其转换成对下式进行求解:

$$\begin{cases} \max \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \\ \text{s.t. } \sum_{i=1}^n y_i \alpha_i = 0, 0 \leq \alpha_i \leq C, i = 1, \dots, n \end{cases} \quad (9)$$

求解完成后, 便可得到对样本进行有效划分的决策函数.

$$f(x) = \text{sgn} \left(\sum_{i=1}^n y_i \alpha_i K(x_i, x) + b \right) \quad (10)$$

式中, $K(x_i, x)$ 表示核函数. $K(x_i, x)$ 有多种形式, 其中式 (11) 所示的径向基核函数最为常用且效果最好.

$$K(x_i, x) = \exp(-g \|x_i - x\|^2) \quad (11)$$

支持向量机算法在数据特征过多时, 会造成故障诊断率下降. 粒子群算法作为一种优化方法, 具有较好的局部搜索能力. 本文通过粒子群优化算法进行特征选择, 并对特征选择后的数据进行故障诊断. 将直接 SVM 故障诊断的结果, 与使用粒子群算法进行特征选择后再进行 SVM 故障诊断的结果对比.

2 故障诊断流程

本文提出的基于 VMD 与支持向量机的锂电池内短路故障诊断流程图如图 2 所示. 首先将锂电池发生内短路故障的信号或正常信号作为输入进行 VMD 分解, 利用该方法求出了一组 IMF 分量, 并计算每个 IMF 的样本熵, 构成了特征向量, 然后将输入的所有信号分成训练集和测试集, 最后将分组的特征向量分别输入到 SVM 模型于 PSO-SVM 模型中进行训练与故障诊断.




图2 锂电池内短路故障诊断流程图

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

3 仿真实验及结果

3.1 信号分解

本文所选用电极为三元锂离子电池, 充电截止电压为 4.2 V, 放电截止电压为 2.5 V, 数据长度为

1000, 数据来源为文献 [21]. 其发生内短路故障与正常状态下其电压信号如下图 3 所示. 可以看出, 由于短暂电压压降存在时间较短, 其潜在的内短路故障极有可能被忽略.




图3 锂电池电压信号.(a) 锂电池内短路电压故障信号;(b) 锂电池正常电压信号

Fig.3 Lithium battery voltage signal: (a) short-circuit voltage fault signal in lithium battery; (b) lithium battery normal voltage signal

进行 VMD 分解时, 惩罚因子 α 和分解层数 K 对 VMD 的分解结果有很大影响. 本文以任一锂电池内短路故障信号为例, 设置鲸鱼族群数目为 10, 鲸鱼个体数量为 30, 迭代次数为 30^[29], K 的取值范围为 [2, 15] 内的整数, 惩罚参数 α 取值范围为 [100, 10000] 内的整数. 得到的 WOA-VMD 收敛曲线如图 4 所示, 可以看出 WOA 寻优过程中适应度最小值 0.0372 出现在第 2 次迭代, 并寻得最优分解模态个数 K 值为 10, 最优惩罚因子 α 为 1997. 当 $K=10$, $\alpha=1997$ 时 VMD 分解及其频谱图如图 5 所示.




图4 WOA-VMD 收敛曲线

Fig.4 Convergence curve of WOA-VMD

为了加强对比效果, 对信号进行经验模态分解(EMD)与集合经验模态分解(EEMD), 分解后的模态分量及其对应频谱如图 6 与图 7 所示. 结果表明, EMD 与 EEMD 分解效果并不理想, 在 IMF1 分量中均出现了产生模态混叠现象. EMD 分解的 IMF4

至 IMF7 均为额外的虚假分量, EEMD 分解中的 IMF5 至 IMF8 同样为多余的虚假分量.

由以上分析可知, VMD 在信号分解方面比 EMD 与 EEMD 更具优势.

3.2 特征提取

本文通过各 IMF 的样本熵值判断故障类型. 锂离子电池内短路故障信号进行 VMD 分解后得到 10 个模态分量, 计算各分量样本熵值作为特征向量; 然后将其与电池正常信号的样本熵值输入到支持向量机中, 实现锂离子电池内短路故障的故障诊断.

对锂离子电池经 VMD 分解后各模态分量的样本熵进行计算形成特征向量, 图 8 分别列出了锂离子电池电压信号在发生内短路故障与正常两种状态下经 VMD 分解后的模态分量样本熵值. 尤其在 IMF2 与 IMF4 中, 可以明显看出锂离子电池发生内短路故障时与正常信号的样本熵值相差较大, 因此 IMF 的样本熵可以作为故障类型的判别指标之一.

3.3 故障诊断

两种状态下的电池数据各取 30 组数据, 共计 60 组数据. 两种状态的数据中分别随机抽取 15 组, 共计 30 组作为 SVM 与 PSO-SVM 模型的训练集; 然后将余下的 30 组数据, 用作 SVM 与 PSO-SVM 模型的测试集, 分别用来进行训练与测试.

本文采用 MATLAB 编程语言来构建 SVM 与 PSO-SVM 模型, 针对锂电池发生内短路故障状态




图5 锂电池故障信号 VMD 分解.(a)VMD 分解;(b)VMD 各分量对应频谱

Fig.5 VMD decomposition of lithium battery fault signal: (a) VMD decomposition; (b) spectrum corresponding to each component of VMD

与正常状态, 本文将标签设置为: 锂电池正常状态为 1, 锂离子电池内短路故障为 2. 将分解后的各 IMF 分量样本熵值作为输入, 分别建立 SVM, PSO-SVM 故障诊断模型, 得到故障诊断结果如图 9 与图 10 所示. 其中, 通过粒子群算法对输入向量进行特征

选择后, 从 10 个特征中选择了第 1、2、4、6、7、9 共 6 个特征分量, 部分输入信号的模态分量样本熵值如表 1 所示.

如表 2 所示分别为基于 SVM 模型与 PSO-SVM 模型的故障诊断结果. 对比两次结果可知, 经粒子




图 6 锂电池故障信号 EMD 分解.(a)EMD 分解;(b)EMD 各分量对应频谱

Fig.6 EMD decomposition of lithium battery fault signal: (a) EMD decomposition; (b) spectrum corresponding to each component of EMD




图7 锂电池故障信号 EEMD 分解.(a)EEMD 分解;(b)EEMD 各分量对应频谱

Fig.7 EEMD decomposition of lithium battery fault signal: (a) EEMD decomposition; (b) spectrum corresponding to each component of EEMD

群算法进行特征选择后, SVM 的故障诊断精度有了明显提高.

4 结论

本文结合 VMD 分解、样本熵和 SVM 的特点,




图 8 锂电池故障与正常电压的熵值分解对比

Fig.8 Comparison of entropy decomposition between lithium battery fault and normal voltage




图 9 SVM 故障分类模型

Fig.9 SVM fault classification model




图 10 PSO-SVM 故障分类模型

Fig.10 PSO-SVM fault classification model

提出基于 WOA-VMD 和 PSO-SVM 的锂电池内短路故障诊断算法. 结果表明, 该方法计算过程简单, 故障识别有效.

(1) 通过将 VMD 分解与 EMD、EEMD 分解相比, 结果表明 VMD 分解能够有效避免锂电池内短路故障信号分解时模态混叠现象的出现.

(2) VMD 分解时有两个对分解结果影响较大的参数: K 和 α . 通过 WOA 算法对其进行寻优, 最终寻得最优参数组合 $K=10$, $\alpha=1997$, 分解出的 IMF 分量可以作为 SVM 的特征输入向量.

(3) 与直接 SVM 模型相比, 基于 PSO-SVM 模型的锂离子电池内短路故障诊断算法具有更高的诊断精度与分类准确率.

表 1 两种状态下特征向量及其识别效果

Table 1 Eigenvectors in two states and their recognition effects

Battery status	Feature vector						True category	Forecast category
	IMF1	IMF2	IMF4	IMF6	IMF7	IMF9		
Internal short-circuit fault	0.0050	0.0559	0.1050	0.0151	0.0033	0.0006	1	1
	0.0061	0.0518	0.0502	0.0035	0.0001	0.0003	1	1
	0.0064	0.0595	0.0396	0.0059	0.0019	0.002	1	1
Normal	0.0037	0.1308	0.0632	0.0018	0.0042	0.0011	2	2
	0.0032	0.0272	0.0571	0.0096	0	0.0011	2	2
	0.0032	0.0558	0.0241	0.0065	0.0016	0.0003	2	2

表 2 经粒子群算法优化前后的诊断结果

Table 2 Diagnosis results before and after PSO

Fault diagnosis method	Recognition rate/%
SVM	66.667
PSO-SVM	96.667

参 考 文 献

[1] Li K X. *Research on Thermal Characteristics and Thermal*

Management System of Electric Vehicle Power Battery [Dissertation]. Tianjin: Tianjin University, 2019

(李恺翔. 电动汽车动力电池热特性及热管理方式研究 [学位论文]. 天津: 天津大学, 2019)

[2] Ma R X, Liu J Z, Wang S F, et al. Progress on thermal runaway propagation characteristics and prevention strategies of lithium-ion batteries. *Chin Sci Bull*, 2021, 66(23): 2991

(马瑞鑫, 刘吉臻, 汪双凤, 等. 锂离子电池热失控扩展特征及抑制策略研究进展. 科学通报, 2021, 66(23): 2991)

- [3] Long Y, Zhou X Z, Wang Z G, et al. Safety design of power Li-ion battery for rail transit vehicle. *Battery Bimon*, 2021, 51(6): 614
(龙源, 周兴振, 王占国, 等. 轨道交通车辆用动力锂离子电池的安全设计. 电池, 2021, 51(6): 614)
- [4] Sun Z Y, Wang Z P, Liu P, et al. Overview of fault diagnosis in new energy vehicle power battery system. *J Mech Eng*, 2021, 57(14): 87
(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. 机械工程学报, 2021, 57(14): 87)
- [5] Qin X W, Du H J, Li M M, et al. Energy storage system design for safety performance improvement. *Power Energy*, 2021, 42(5): 504
(秦晓维, 杜海江, 李明明, 等. 提升安全性能的储能系统设计. 电力与能源, 2021, 42(5): 504)
- [6] Zhang C J, Shi M D, Xu C, et al. Intrinsic safety mechanism and case analysis of energy storage systems based on dynamically reconfigurable battery network. *Energy Storage Sci Technol*, 2022, 11(8): 2442
(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. 储能科学与技术, 2022, 11(8): 2442)
- [7] Liu H Y, Yang L, Li J L. Battery fault identification based on long-short-term memory networks. *Mechatronics*, 2020, 26(S1): 17
(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. 机电一体化, 2020, 26(S1): 17)
- [8] Shan T X, Wang Z P, Hong J C, et al. Overview of “mechanical abuse-thermal runaway” of electric vehicle power battery and its safety prevention and control technology. *J Mech Eng*, 2022, 58(14): 252
(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. 机械工程学报, 2022, 58(14): 252)
- [9] Yang R X, Xiong R, Sun F C. Experimental platform development and characteristics analysis of external short circuit in lithium-ion batteries. *J Electr Eng*, 2021, 16(1): 103
(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. 电气工程学报, 2021, 16(1): 103)
- [10] Su W, Zhong G B, Shen J N, et al. The progress in fault diagnosis techniques for lithium-ion batteries. *Energy Storage Sci Technol*, 2019, 8(2): 225
(苏伟, 钟国彬, 沈佳妮, 等. 锂离子电池故障诊断技术进展. 储能科学与技术, 2019, 8(2): 225)
- [11] Yang J, Lin Z K, Tang J, et al. A review of fault characteristics, fault diagnosis and identification for lithium-ion battery systems. *CIESC J*, 2022, 73(8): 3394
(杨静, 林振康, 汤君, 等. 电池系统的故障特征以及多故障的诊断与识别. 化工学报, 2022, 73(8): 3394)
- [12] Zhu X Q, Wang Z P, Hsin W, et al. Review of thermal runaway and safety management for lithium-ion traction batteries in electric vehicles. *J Mech Eng*, 2020, 56(14): 91
(朱晓庆, 王震坡, WANG Hsin, 等. 锂离子动力电池热失控与安全管控研究综述. 机械工程学报, 2020, 56(14): 91)
- [13] Wang Z F, Luo W, Yan Y, et al. Summary of research on multi-fault diagnosis strategies of lithium-ion power battery sensors. *Sci Technol Eng*, 2022, 22(27): 11761
(王志福, 罗崑, 闫愿, 等. 锂离子动力电池传感器多故障诊断策略综述. 科学技术与工程, 2022, 22(27): 11761)
- [14] 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. *Appl Energy*, 2016, 184: 365
- [15] Feng X N, Pan Y, He X M, et al. Detecting the internal short circuit in large-format lithium-ion battery using model-based fault-diagnosis algorithm. *J Energy Storage*, 2018, 18: 26
- [16] Feng X N, Weng C H, Ouyang M G, et al. Online internal short circuit detection for a large format lithium ion battery. *Appl Energy*, 2016, 161: 168
- [17] Zhang M X, Du J Y, Liu L S, et al. Internal short circuit detection method for battery pack based on circuit topology. *Sci China Technol Sci*, 2018, 61(10): 1502
- [18] Chen Z Q, Chen X D, Olivira J, et al. Application of deep learning in equipment prognostics and health management. *Chin J Sci Instrum*, 2019, 40(9): 206
(陈志强, 陈旭东, José Valente de Oliveira, 等. 深度学习在设备故障预测与健康管理中的应用. 仪器仪表学报, 2019, 40(9): 206)
- [19] Wang C, Yuan Z Y, Wang Y W, et al. Overview of key technologies for echelon utilization of decommissioned power batteries. *Adv N Renew Energy*, 2021, 9(4): 327
(王存, 袁智勇, 王亦伟, 等. 退役动力电池梯次利用关键技术概述. 新能源进展, 2021, 9(4): 327)
- [20] Li T M, Si X S, Liu X, et al. Data-model interactive remaining useful life prediction technologies for stochastic degrading devices with big data. *Acta Autom Sin*, 2022, 48(9): 2119
(李天梅, 司小胜, 刘翔, 等. 大数据下数模联动的随机退化设备剩余寿命预测技术. 自动化学报, 2022, 48(9): 2119)
- [21] Jiang L L, Deng Z W, Tang X L, et al. Data-driven fault diagnosis and thermal runaway warning for battery packs using real-world vehicle data. *Energy*, 2021, 234: 121266
- [22] Xia B, Shang Y L, Nguyen T, et al. A correlation based fault detection method for short circuits in battery packs. *J Power Sources*, 2017, 337: 1
- [23] Naha A, Khandelwal A, Agarwal S, et al. Internal short circuit detection in Li-ion batteries using supervised machine learning. *Sci Rep*, 2020, 10: 1301
- [24] Liu Y H. *Research on Power Forecasting and Dynamic Environmental Economic Dispatch in Power System with Photovoltaic Power Generation* [Dissertation]. Harbin: Northeast Agricultural University, 2021
(刘彦辉. 含光伏发电的电力系统功率预测和动态环境经济调度研究 [学位论文]. 哈尔滨: 东北农业大学, 2021)

- [25] Wang R, Hou Q L, Shi R Y, et al. Remaining useful life prediction method of lithium battery based on variational mode decomposition and integrated deep model. *Chin J Sci Instrum*, 2021, 42(4): 111
(王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法. 仪器仪表学报, 2021, 42(4): 111)
- [26] Yang B C. *Whale Optimization Algorithm-Based Optimum Energy-Management and Battery-Sizing Method for Grid-Connected Microgrids* [Dissertation]. Qinhuangdao: Yanshan University, 2020
(杨柏成. 基于鲸鱼优化算法的微网能量管理与电池容量优化 [学位论文]. 秦皇岛: 燕山大学, 2020)
- [27] Wu Y X, Wang X Z, Cheng Y H, et al. Research on the method of extracting the fault features of walking gearbox of combine harvester. *J Agric Mech Res*, 2022, 44(2): 23
(吴义新, 王新忠, 承银辉, 等. 联合收割机行走变速箱故障特征提取方法研究. 农机化研究, 2022, 44(2): 23)
- [28] Zhai J Q, Yang X X, Cheng Y Q, et al. Overview of application of fault detection and diagnosis based on machine learning. *Comput Meas Contr*, 2021, 29(3): 1
(翟嘉琪, 杨希祥, 程玉强, 等. 机器学习在故障检测与诊断领域应用综述. 计算机测量与控制, 2021, 29(3): 1)
- [29] Zhang P, Zhang W H, Zhao X H, et al. Application of WOA-VMD algorithm in bearing fault diagnosis. *Noise Vib Contr*, 2021, 41(4): 86
(张萍, 张文海, 赵新贺, 等. WOA-VMD 算法在轴承故障诊断中的应用. 噪声与振动控制, 2021, 41(4): 86)