

DOI: 10.19783/j.cnki.pspc.240924

# 考虑非平稳特性的 Vienna 整流器鲁棒故障诊断方法

孙章<sup>1</sup>, 金炜东<sup>1</sup>, 吴帆<sup>2</sup>, 张友华<sup>3</sup>, 吴昀璞<sup>3</sup>

(1. 西南交通大学电气工程学院, 四川 成都 611756; 2. 电子科技大学自动化工程学院, 四川 成都 610095;  
3. 西华大学电气与电子信息学院, 四川 成都 610039)

**摘要:** Vienna 整流器开路故障信号具有非平稳特性, 并且易受传感器噪声、基准偏移和负载变化的干扰, 导致传统故障诊断方法的精度降低。因此, 提出一种基于重要特征提取和改进随机森林故障诊断方法, 用于提高 Vienna 整流器开路故障诊断的精度与鲁棒性。首先分析了 Vienna 整流器开路故障信号的非平稳特性及其产生机理。然后定义最优离散小波变换聚焦信号细节, 实现多尺度故障特征提取。同时考虑特征的相互影响, 采用改进的 ReliefF 算法优选重要特征。在此基础上, 提出鲁棒精度加权的随机森林算法, 表征重要故障特征与故障类别的映射关系, 通过袋外(out-of-bag, OOB)数据的噪声鲁棒测试, 调整决策树的投票权重, 从而增强故障诊断的精度与鲁棒性。最后通过对比实验结果表明: 所提方法具有鲁棒非平稳变化的能力, 准确率可达 99.84%。

**关键词:** Vienna 整流器; 故障诊断; 特征提取; 随机森林; 非平稳特性

## Robust fault diagnosis method for Vienna rectifiers considering non-stationary characteristics

SUN Zhang<sup>1</sup>, JIN Weidong<sup>1</sup>, WU Fan<sup>2</sup>, ZHANG Youhua<sup>3</sup>, WU Yunpu<sup>3</sup>

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China; 2. School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 610095, China; 3. School of Electrical Engineering and Electronic Information, Xihua University, Chengdu 610039, China)

**Abstract:** The open-circuit fault signals of Vienna rectifiers exhibit non-stationary characteristics and are susceptible to sensor noise, reference offset, and load variations, which reduces the performance of traditional fault diagnosis methods. To address this, a fault diagnosis method based on significant feature extraction and improved random forests is proposed to improve the open-circuit fault diagnosis accuracy and robustness of Vienna rectifiers. First, the non-stationary characteristics and underlying mechanisms of open-circuit fault signals in Vienna rectifiers are analyzed. Then, an optimal discrete wavelet transform is defined to focus on signal details, enabling multi-scale fault feature extraction. Meanwhile, considering the mutual effects of the features, the improved ReliefF algorithm is employed to select the most important features. On this basis, a robust accuracy-weighted random forest algorithm is utilized to map important fault features to fault categories. By performing noise robustness testing with the out-of-bag (OOB) data, the voting weights of decision trees are adjusted, thereby enhancing the accuracy and robustness of the fault diagnosis method. Finally, comparative experimental results show that the proposed method is robust to non-stationary variations and achieves an accuracy rate of 99.84%.

This work is supported by the Young Scientists Fund of National Natural Science Foundation of China (No. 62203368).

**Key words:** Vienna rectifier; fault diagnosis; feature extraction; random forest; non-stationary characteristics

## 0 引言

Vienna 整流器具有开关器件少、谐波畸变率低和功率密度高等优点, 广泛应用于新能源发电、电

动汽车充电桩、航空电源和通信电源等高可靠性变流器应用领域<sup>[1-4]</sup>。然而, 功率开关管属于变流器的脆弱部件, 其故障主要有短路和开路两种, 在变流器所有故障类型中的占比较高, 约为 38%<sup>[5]</sup>。当变流器的开关管发生短路故障时, 会产生瞬间的冲击电流, 易触发过流或欠压保护<sup>[6]</sup>。而开路故障发生

基金项目: 国家自然科学基金青年基金项目资助 (62203368)

时的电压和电流变化较为模糊, 难以被保护电路检测识别, 若不及时定位并采取保护措施, 会导致电流畸变和电压不稳定程度加剧, 严重时引起二次故障, 导致安全事故和经济损失。已有研究表明, 利用故障诊断方法实现对开路故障功率开关管的准确定位, 并结合容错控制策略, 可以保障变流器的持续可靠运行<sup>[7-8]</sup>。因此研究 Vienna 整流器的故障诊断方法具有重要价值和现实需求。

现有变流器功率故障诊断方法主要分为基于模型<sup>[9-11]</sup>、基于信号<sup>[12-14]</sup>和数据驱动<sup>[15-18]</sup> 3 种类型。基于模型的故障诊断方法, 利用变流器的数学模型得到预测值, 再判断其与实测值是否一致, 从而实现故障诊断; 此类方法检测快速、易于实现, 但诊断效果受到变流器建模精度和参数不确定变化的影响很大。基于信号的故障诊断方法, 利用检测信号的波动变化实现故障诊断, 相较于基于模型的方法, 无需对变流器进行数学建模, 但需要具备故障先验知识, 且诊断阈值设定困难。基于数据驱动的故障诊断方法, 利用故障历史数据提取故障特征, 并训练机器学习模型拟合故障特征的概率分布; 该方法不需要精确数学模型或故障先验知识, 在变流器故障诊断领域受到了广泛关注。

文献[19]提出了一种基于一维卷积神经网络(1D-convolutional neural network, 1D-CNN)的故障诊断方法, 该方法以输入电流为历史数据, 利用具有自适应学习率调整的诊断模型实现对三电平中点钳位逆变器的故障特征分类。文献[20]提出了一种基于深度信念网络的最小二乘支持向量机(least squares support vector machine, LSSVM)故障诊断方法, 实现 PWM 整流器开路故障诊断。文献[21]提出了一种基于混合集成学习(hybrid ensemble learning, HEL)的三相 PWM 变流器开路故障诊断方法, 该方法采用快速傅立叶变换和 ReliefF 算法得到故障特征, 利用具有参数优化能力的诊断模型实现诊断精度和速度之间的平衡。文献[22]提出了一种基于贝叶斯网络(Bayesian network, BN)的数据驱动故障诊断方法, 解决三相逆变器故障诊断易受传感器偏置、噪声以及不确定性干扰影响的问题。然而, 在有限工况下训练的机器学习模型, 只适用于特定的运行条件, 无法有效应对变流器多工况变化和不确定干扰的影响, 导致故障诊断精度显著降低<sup>[23]</sup>。

随机森林算法(random forests, RFs)是一种集成多个弱分类器, 以构建强分类器的机器学习模型, 对异常值和噪声具有一定的鲁棒性, 在故障诊断领域得到了发展应用<sup>[24-29]</sup>。文献[28]提出了一种基于电流轨迹斜率和随机森林结合的中点钳位(neutral

point clamped, NPC)逆变器开路故障诊断方法, 具有较好的鲁棒性与精度。文献[29]提出了一种基于暂态综合特征结合随机森林的故障诊断方法, 实现了三相 PWM 整流器开路故障的快速准确诊断。然而, Vienna 整流器受强非线性和多环路闭环控制的影响, 其开路故障特征随着时间变化呈现严重的周期非平稳特性。同时, 该周期非平稳特性易受到传感器噪声、基准偏移和负载变化影响, 导致机器学习模型无法准确拟合故障特征的概率分布, 从而会降低故障诊断的准确率。

为此, 本文基于重要特征提取与改进随机森林, 提出一种考虑非平稳特性的 Vienna 整流器鲁棒故障诊断方法。首先以输入电流作为诊断信号, 分析开路故障非平稳特性的产生机理及其影响因素。然后定义信息成分函数, 实现最优离散小波变换, 提取多尺度时频故障特征; 进一步考虑特征的相互影响, 采用改进 ReliefF(improved ReliefF, IReliefF)算法优选重要故障特征。在此基础上, 提出鲁棒精度加权的随机森林算法, 表征重要故障特征与故障类别的映射关系, 并利用袋外数据的噪声鲁棒测试调整决策树投票权重, 以增强故障分类器的鲁棒性, 从而实现开关管开路故障的准确定位。最后, 通过对比实验结果证明, 相较于 1D-CNN、LSSVM、HEL、BN 和 RFs 等其他 5 种方法, 所提方法有效增强了对 Vienna 整流器开路故障诊断的精度和鲁棒性。

## 1 Vienna 整流器故障非平稳特性分析

### 1.1 拓扑结构与开路故障类型

本文研究的 Vienna 整流器拓扑结构如图 1 所示。其中:  $e_a$ 、 $e_b$ 、 $e_c$  和  $i_a$ 、 $i_b$ 、 $i_c$  分别为三相输入的电压和电流;  $L_a$ 、 $L_b$ 、 $L_c$  分别为三相输入的滤波电感;  $D_1$ — $D_6$  分别为 6 个整流二极管;  $T_1$ — $T_6$  分别为 6 个功率开关管;  $D_{T_1}$ — $D_{T_6}$  分别为 6 个续流二极管;  $C_1$  和  $C_2$  分别为直流侧的上、下电容。常见的开路故障有单管和双管故障<sup>[8]</sup>, 若将正常状态也视为一种故障, 则共有 22 种单管或双管功率开关管开路故障类型, 定义故障标签如表 1 所示。

当 Vienna 整流器发生开路故障时, 三相输入电流产生不规则变化, 采用输入电流进行故障诊断, 就可以利用已有的电流采样单元, 实现非侵入式和无需附加传感器的故障诊断<sup>[30]</sup>。本文所提方法通过现场可编程门阵列(field-programmable gate array, FPGA)中的数据缓存单元存储一个周期的三相输入电流信号, 利用数据驱动训练的诊断模型输出故障标签, 并结合表 1 实现故障定位。

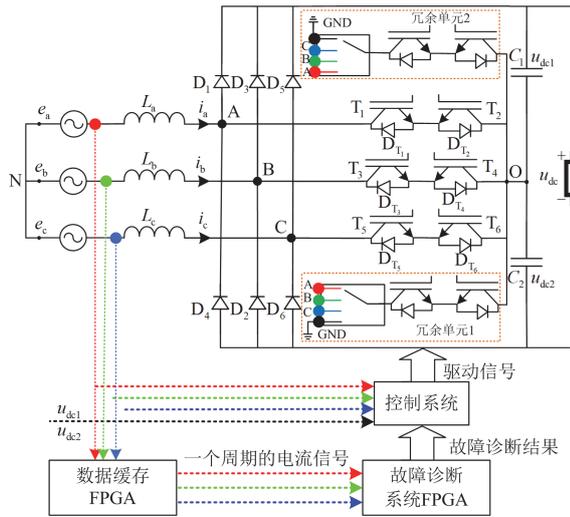


图1 Vienna 整流器拓扑

Fig. 1 Topology of Vienna rectifier

表1 开路故障类型标签

Table 1 Label of open-circuit faults

开路类型	故障标签	开路类型	故障标签
无	0	T <sub>1</sub> &T <sub>6</sub> (T <sub>16</sub> )	11
T <sub>1</sub>	1	T <sub>2</sub> &T <sub>3</sub> (T <sub>23</sub> )	12
T <sub>2</sub>	2	T <sub>2</sub> &T <sub>4</sub> (T <sub>24</sub> )	13
T <sub>3</sub>	3	T <sub>2</sub> &T <sub>5</sub> (T <sub>25</sub> )	14
T <sub>4</sub>	4	T <sub>2</sub> &T <sub>6</sub> (T <sub>26</sub> )	15
T <sub>5</sub>	5	T <sub>3</sub> &T <sub>4</sub> (T <sub>34</sub> )	16
T <sub>6</sub>	6	T <sub>3</sub> &T <sub>5</sub> (T <sub>35</sub> )	17
T <sub>1</sub> &T <sub>2</sub> (T <sub>12</sub> )	7	T <sub>3</sub> &T <sub>6</sub> (T <sub>36</sub> )	18
T <sub>1</sub> &T <sub>3</sub> (T <sub>13</sub> )	8	T <sub>4</sub> &T <sub>5</sub> (T <sub>45</sub> )	19
T <sub>1</sub> &T <sub>4</sub> (T <sub>14</sub> )	9	T <sub>4</sub> &T <sub>6</sub> (T <sub>46</sub> )	20
T <sub>1</sub> &T <sub>5</sub> (T <sub>15</sub> )	10	T <sub>5</sub> &T <sub>6</sub> (T <sub>56</sub> )	21

1.2 开路故障非平稳特性分析

Vienna 整流器发生开路故障时的电流通路被破坏, 以 T<sub>1</sub> 开路为例, 分析 Vienna 整流器开路故障后输入电流波形的非平稳特性。T<sub>1</sub> 发生开路故障后, 实验测量输入电流波形如图 2 所示, 出现了零电流平台 (zero current platform, ZCP)、不可控整流 (uncontrollable rectification, UR) 和无影响阶段 (unaffected stage, US) 等 3 个过程交替出现。

具体分析如下, 当 T<sub>1</sub> 正常, 且 e<sub>a</sub> > 0 时, i<sub>a</sub> 通过 D<sub>1</sub> 或 T<sub>1</sub> → D<sub>T<sub>2</sub></sub> 流入直流侧, 如图 3(a) 所示; 当 T<sub>1</sub> 开路故障时, T<sub>1</sub> → D<sub>T<sub>2</sub></sub> 通路破坏, 如果二极管 D<sub>1</sub> 的电压 U<sub>D<sub>1</sub></sub> < U<sub>on</sub> (U<sub>on</sub> 为开通电压), D<sub>1</sub> 电流通路也被破坏, 如图 3(b) 所示, 则出现零电流平台; 若 U<sub>D<sub>1</sub></sub> ≥ U<sub>on</sub>, i<sub>a</sub> 通过 D<sub>1</sub> 流入直流侧, 如图 3(c) 所示,

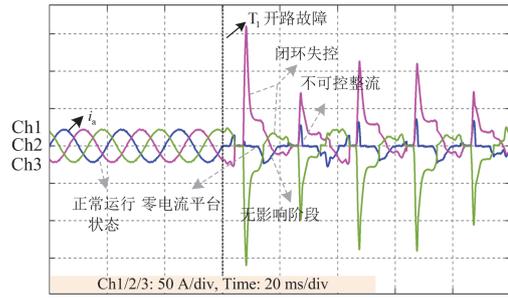


图2 T<sub>1</sub> 开路故障输入电流波形

Fig. 2 Input current waveform of T1 open-circuit faults

形成不可控整流; 若 e<sub>a</sub> < 0, i<sub>a</sub> 通过 T<sub>2</sub> → D<sub>T<sub>1</sub></sub> 或 D<sub>4</sub> 路径返回交流侧, 此时 i<sub>a</sub> 电流不受 T<sub>1</sub> 开路故障影响, 称为无影响阶段, 如图 3(d) 所示。依据上述分析可知, i<sub>a</sub> 的非平稳特性与电网电压和二极管电压紧密相关, 二极管电压 U<sub>D<sub>z</sub></sub> 如式(1)所示。

$$U_{D_z} = e_x - L \frac{di_x}{dt} - U_{NO} - U_{dck} \quad (1)$$

式中: z = 1, 2, ..., 6; x = a, b, c; k = 1, 2; U<sub>NO</sub> 和 U<sub>dck</sub> 分别为零序电压和电容电压, 它们与功率开关管的驱动紧密相关, 而驱动信号由 Vienna 整流器多环路控制所得<sup>[31]</sup>。根据上述分析可知, T<sub>1</sub>—T<sub>6</sub> 发生开路故障的相似规律归纳如表 2 所示。当故障电流通路被破坏时, 强非线性系统的多环路控制使 U<sub>NO</sub>、U<sub>dck</sub> 具有时变特性, 导致 i<sub>a</sub>、i<sub>b</sub>、i<sub>c</sub> 具有无法预测的周期非平稳特性。

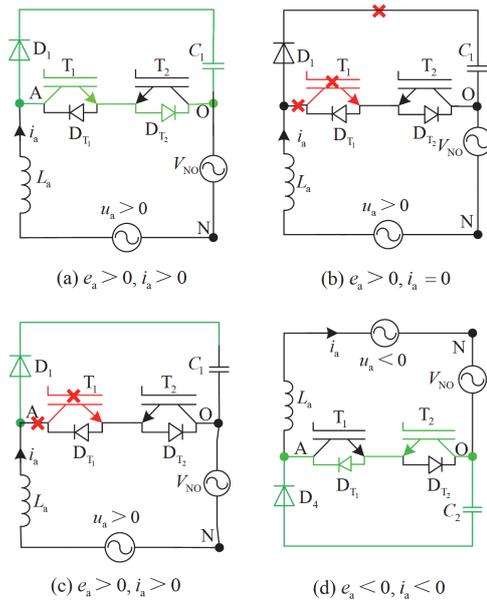


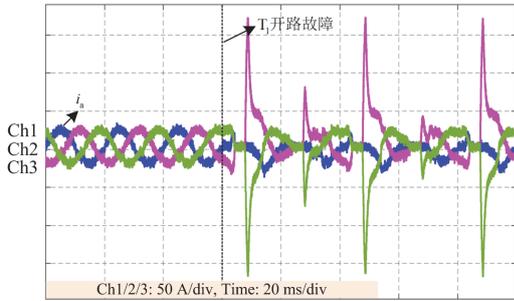
图3 T<sub>1</sub> 开路故障时的 A 相电流路径

Fig. 3 A-phase current path of T<sub>1</sub> open-circuit faults

表 2 单管开路时的零电流平台

开关管	ZCP	UR	US
T <sub>1</sub>	$e_a > 0 \& U_{D_1} < U_{on}$	$e_a > 0 \& U_{D_1} > U_{on}$	$e_a < 0$
T <sub>2</sub>	$e_a < 0 \& U_{D_2} > U_{on}$	$e_a < 0 \& U_{D_2} < U_{on}$	$e_a > 0$
T <sub>3</sub>	$e_b > 0 \& U_{D_3} < U_{on}$	$e_b > 0 \& U_{D_3} > U_{on}$	$e_b < 0$
T <sub>4</sub>	$e_b < 0 \& U_{D_4} > U_{on}$	$e_b < 0 \& U_{D_4} < U_{on}$	$e_b > 0$
T <sub>5</sub>	$e_c > 0 \& U_{D_5} < U_{on}$	$e_c > 0 \& U_{D_5} > U_{on}$	$e_c < 0$
T <sub>6</sub>	$e_c < 0 \& U_{D_6} > U_{on}$	$e_c < 0 \& U_{D_6} < U_{on}$	$e_c > 0$

此外, 式(1)表明二极管电压  $U_{D_x}$  受  $L(di_x/dt)$  影响, 因此周期非平稳过程对  $i_x$  的变化十分敏感, 而  $i_x$  主要受负载变化、电流传感器噪声和基准偏移等不确定干扰影响。图 4 为典型电流传感器噪声扰动下单管(T<sub>1</sub>)开路的三相输入电流波形, 其周期非平稳过程受到了显著影响。

图 4 噪声扰动下的 T<sub>1</sub> 开路故障电流波形Fig. 4 Waveforms of current during T<sub>1</sub> open fault with noise disturbance

综上所述, Vienna 整流器开路故障破坏了原有的电流路径, 导致输入电流呈现 ZCP、UR 和 US 交替且无法预测的周期非平稳变化, 同时容易受到负载扰动、传感器噪声和基准偏移的影响。机器学习模型本质是提取训练数据集中样本的特征概率分布, 当面对周期非平稳变化的故障特征, 其概率分布随时间偏移, 难以准确拟合。

## 2 故障诊断方法

### 2.1 特征提取与优选

本文通过最优离散小波变换(optimum discrete wavelet transform, ODWT)实现对周期非平稳故障信号的多尺度时频域分解, 聚焦故障信号细节得到时频域特征集。然后, 利用 IReliefF 从时频域特征集中优选重要故障特征。

#### 2.1.1 最优离散小波变换

DWT 将故障信号  $x[n]$  经高通滤波器  $h[n]$  和 low 通滤波器  $g[n]$  进行分解, 得到细节系数  $d_j$  和近似系

数  $a_j$  如图 5 所示<sup>[32]</sup>。图中:  $a_j$  代表低频成分;  $d_j$  代表高频成分;  $f_s$  代表采样频率。尺度函数  $\phi(t)$ 、小波函数  $\psi(t)$  和重构信号  $x(t)$  的计算分别如式(2)和式(3)所示。

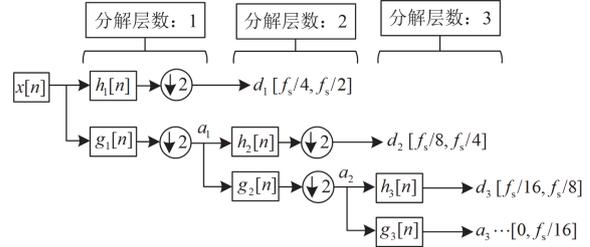


图 5 离散小波变换示意图

Fig. 5 Schematic diagram of discrete wavelet transform

分解表达式为

$$\begin{cases} \phi_{j,k}(t) = 2^{-\frac{j}{2}} \phi(2^{-j}t - k) \\ \psi_{j,k}(t) = 2^{-\frac{j}{2}} \psi(2^{-j}t - k) \\ a_{j,k} = \sum_k x(t) \overline{\phi_{j,k}(t)} \\ d_{j,k} = \sum_k x(t) \overline{\psi_{j,k}(t)} \end{cases} \quad (2)$$

重构表达式为

$$x(t) = \sum_k a_{J,k} \phi_{J,k}(t) + \sum_{j=1}^J \sum_k d_{j,k} \psi_{j,k}(t) \quad (3)$$

式中:  $\overline{\phi_{j,k}(t)}$  和  $\overline{\psi_{j,k}(t)}$  分别为  $\phi_j(t)$  和  $\psi_j(t)$  的共轭;  $J$  代表分解的总层数。分别计算  $d_j$  ( $j=1,2,3,\dots,J$ ) 和  $a_j$  的时域统计信息与频域特征, 时域统计信息包括: 平均值、均方根、标准差、熵、能量、偏度、峰度、对比度、均匀性和相关性, 频域特征为傅里叶变换频率赋值系数, 通过快速傅里叶变换(fast Fourier transform, FFT)获取。

选取不同的  $\psi(t)$  和  $J$  会得到不同性质的故障特征, 为使经过离散小波变换所得到的多尺度时频域特征中含有能够应对周期非平稳变化的重要故障特征, 需选取最佳的  $\psi(t)$  与  $J$ 。考虑到 Vienna 整流器在故障情况下输入电流的高频谐波分量增加, 因此, 本文定义了故障信息成分函数  $F_{IC}(D_J)$  如式(4)所示, 以求取最优的  $J$  和  $\psi(t)$ 。

$$F_{IC}(D_J) = \sqrt{\frac{1}{N_J} \sum_n^{N_J} (D_J(n) - m_{\text{can}}(D_J))^2} \quad (4)$$

式中:  $D_J$  为  $d_j$  ( $j=1,2,3,\dots,J$ ) 的重构信号;  $m_{\text{can}}(D_J)$  为  $D_J$  的平均值。

通过枚举  $\psi(t)$  和  $J$ , 求取使得  $F_{IC}(D_J)$  最大的

分解方式为:  $J=4$ 、 $\psi(t)=DB4$ 。以  $T_1$  故障为例, ODWT 的部分效果如图 6 所示。A 相故障电流  $i_a$  变换前具有周期非平稳特性, 采用 ODWT 分解重构后的故障信号具有周期变化特性, 即通过 ODWT 分解, 聚焦信号细节, 分解信号中含有可应对非平稳特性的故障特征。

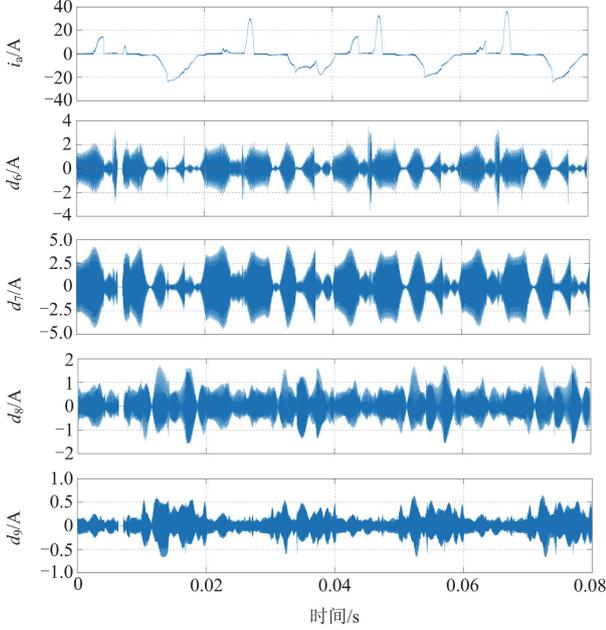


图 6 最优离散小波变换重构波形

Fig. 6 Reconstructed waveforms of the ODWT

### 2.1.2 改进的 ReliefF 优选方法

ReliefF 算法通过特征权重评估特征的重要性, 重要的特征可以使同类样本接近, 不同类样本远离, 对周期非平稳变化具有鲁棒性。因此, 特征权重可以通过计算某一特征到同类样本的平均距离和不同类样本的平均距离来评估特征的重要性<sup>[33]</sup>。传统 ReliefF 算法通常只考虑了特征的独立权重, 而忽略了特征的相互影响权重。然而, 单一特征的故障分类能力较弱, 若与其他特征组合, 将会达到更好的分类能力。

在传统 ReliefF 基础上, 本文提出改进 ReliefF 算法(IReliefF), 根据某一特征选择/舍弃下平均距离的差异, 调整特征权重。

$$W[x_n]^{i+1} = W[x_n]^i + P[X]^i - P[X_{x_n}]^i + P[x_n]^i \quad (5)$$

式中:  $W[x_n]^i$  表示第  $i$  次迭代时特征  $x_n$  的初始权重;  $X$  表示全部特征向量;  $X_{x_n}$  表示去除特征  $x_n$  后的特征向量;  $P[X]^i - P[X_{x_n}]^i$  表示第  $i$  次迭代时的相互影响权重;  $P[x_n]^i$  表征第  $i$  次迭代时的独立权重。其中,  $P[X]^i$  用于衡量特征向量  $X$  的样本类别区分能力,

$P[X]^i$  越大则同类样本的距离越近, 不同类样本的距离越远, 区分能力就越强,  $P[X]^i$  的定义如式(6)所示。

$$P[X]^i = S_{DD}(X) - A_{DS}(X) \quad (6)$$

式中:  $S_{DD}(X)$ 、 $A_{DS}(X)$  分别为特征向量  $X$  的不同类样本平均距离和同类样本平均距离。

$$S_{DD}(X) = \frac{\sum_{j=1}^k \frac{p_{\text{rior}}(c_{\text{lass}}(M_j))}{1 - p_{\text{rior}}(c_{\text{lass}}(R_i))} d_{\text{is}}(X, R_i, M_j)}{(Nk)} \quad (7)$$

$$A_{DS}(X) = \sum_{j=1}^k d_{\text{is}}(X, R_i, H_j) / (Nk) \quad (8)$$

式中:  $R_i$  为  $i$  次迭代采样样本;  $H$  表示采样  $k$  个与  $R_i$  相同类样本;  $M$  表示采样  $k$  个与  $R_i$  不同类样本;  $M$  为迭代总次数;  $c_{\text{lass}}(R_i)$  为类别;  $p_{\text{rior}}$  函数用于计算先验概率;  $d_{\text{is}}$  函数计算两个实例  $R_i$  和  $H_j$  以  $X$  为特征在特征空间中的欧式距离, 如式(9)所示。

$$d_{\text{is}}(X, R_i, M_j) = \frac{|v_{\text{alue}}(X, R_i) - v_{\text{alue}}(X, M_j)|}{\max(X) - \min(X)} \quad (9)$$

式中:  $v_{\text{alue}}(X, R_i)$  为样本  $R_i$  以  $X$  为特征的取值;  $v_{\text{alue}}(X, M_j)$  为样本  $M_j$  以  $X$  为特征的取值;  $\max(X) - \min(X)$  为最大值与最小值之差。

综上, IReliefF 算法实现过程如式(5)~式(9)所示, 该算法在 ODWT 的基础上, 进一步得到对周期非平稳变化具有鲁棒性的重要故障特征, 增强故障分类器的鲁棒性。

## 2.2 改进的随机森林故障分类算法

本文基于 RFs 的分类误差理论, 提出改进的随机森林(improved random forests, IRFs)故障分类算法。IRFs 利用袋外(out-of-bag, OOB)数据的噪声鲁棒测试, 增强诊断模型对异常值和噪声的容忍性。该算法以 ODWT + IReliefF 得到的重要故障特征为输入, 输出为故障标签, 实现故障定位。

### 2.2.1 随机森林误差分析理论

RFs 结合了 Bagging 集成学习理论与随机子空间算法, 由  $N$  个决策树投票得到分类结果。当  $N$  足够大时, 在大数定律的保证下, 随机森林的泛化误差  $E^*$  趋于上界稳定, 如式(10)所示。

$$E^* \leq \frac{\rho(1-s^2)}{s^2} \quad (10)$$

式中:  $s$  表征决策树的平均分类能力,  $s$  越大, 则 RFs 性能越好<sup>[34]</sup>;  $\rho$  表征决策树之间的相关性。由式(10)表明, 提高  $s$  是增强 RFs 性能的有效途径。此外, 由于采用了有放回的随机采样, 每一棵决策

树存在大量的未使用样本(OOB 样本), 并且此类样本在泛化误差估计和特征重要性评估等方面均具有十分重要的价值<sup>[35-36]</sup>。受上述启发, 本文提出一种改进的鲁棒精度加权的 RFs 算法。

### 2.2.2 鲁棒精度加权的 RFs 算法

本文所提方法在 OOB 数据中引入随机噪声来模拟实际工况中的扰动, 评估单个决策树在噪声扰动作用下的故障诊断性能。根据评估结果, 提高性能较强决策树的投票权重, 使得 RFs 分类结果倾向于强分类性能的决策树, 以增强 RFs 的平均强度。

首先进行数据集采样, 采样验证数据集  $P$  来自实际实验系统, 训练数据集  $T$  来自仿真系统, 令  $r_{pt}$  为  $P$  与  $T$  的数量之比。在第  $i$  个决策树训练阶段, 从训练数据集  $T$  中采样 OOB 数据集  $O_i$  和训练数据子集  $S_i$ , 令  $r_{os}$  为  $O_i$  与  $S_i$  的数量之比。

然后在  $O_i$  的每一个特征中根据特征的最大幅值  $\max(x_i)$ , 加入均值为  $m$ 、方差为  $v$  的高斯白噪声, 用以模拟实际系统中的扰动(传感器噪声和基准偏移), 记为  $\delta_i \sim x_{i,\max} \mathcal{N}(\frac{m}{\max(x_i)}, \frac{v}{\max(x_i)^2})$ 。由于  $P$  和

$\tilde{Q}_i$  ( $\tilde{Q}_i = O_i + \delta_i$ ) 中的数据表征了实际运行工况中的不确定性干扰, 因此决策树在数据集  $P$  和  $\tilde{Q}_i$  中的分类精度可以反映其故障诊断能力。当决策树在数据集  $P$  和  $\tilde{Q}_i$  中的分类精度较差时, 表明当前的决策树对不确定性干扰敏感, 则降低该决策树投票权重, 反之, 则增加该决策树投票权重, 依据此原理, 可以得到第  $i$  棵决策树的投票权重  $w_i$  如式(11)所示。

$$w_i = \alpha w_{\tilde{Q}_i} + (1 - \alpha) w_{P_i}, i = 1, 2, \dots, N \quad (11)$$

$$w_{\tilde{Q}_i} = \frac{N_{\tilde{Q}_i}^{\text{corr}}}{N_o}, i = 1, 2, \dots, N \quad (12)$$

$$w_{P_i} = \frac{N_{P_i}^{\text{corr}}}{N_p}, i = 1, 2, \dots, N \quad (13)$$

式中:  $w_{\tilde{Q}_i}$  和  $w_{P_i}$  分别为第  $i$  个决策树在数据集  $\tilde{Q}_i$  和  $P$  中的故障分类精度权重, 并将其定义为正确分类样本数与测试样本总数之比;  $\alpha$  为权重系数;  $N_{\tilde{Q}_i}^{\text{corr}}$  和  $N_{P_i}^{\text{corr}}$  分别为第  $i$  个决策树在  $\tilde{Q}_i$  和  $P$  中的分类正确数;  $N_o$  和  $N_p$  分别为  $\tilde{Q}_i$  和  $P$  的样本总数。在此基础上, 利用式(14)输出故障类型标签。

$$H(X) = \arg \max_y \sum_{i=1}^N w_i I(h_i(X) = y) \quad (14)$$

式中:  $X$  为输入向量;  $y$  代表故障标签;  $I(\cdot)$  为指示函数;  $h_i(X)$  为第  $i$  个决策树的分类结果。

综上, 利用所获数据集叠加高斯分布噪声, 训练优化 C4.5 算法所得决策树的投票权重, 有效提高 RFs 的分类精度与鲁棒性。

### 2.3 故障诊断流程

本文提出故障诊断方法的实现流程如图 7 所示, 主要包含离线训练和在线应用两个阶段。在离线训练阶段, 首先利用仿真和实验模拟 Vienna 整流器的开路故障, 获得故障数据, 采用归一化预处理故障电流信号, 并依据超参数  $r_{pt}$  将故障数据分为训练集  $T$  和验证集  $P$ 。然后利用 ODWT 提取多尺度时频故障特征, 并采用 IReliefF 算法优选重要故障特征。然后, 训练 IRFs 故障诊断模型, 并采用粒子群优化(particle swarm optimization, PSO)算法<sup>[28]</sup>进行模型中超参数的优选。在线应用阶段, 利用所提出的故障诊断方法输出故障标签, 并结合表 1 实现故障定位。

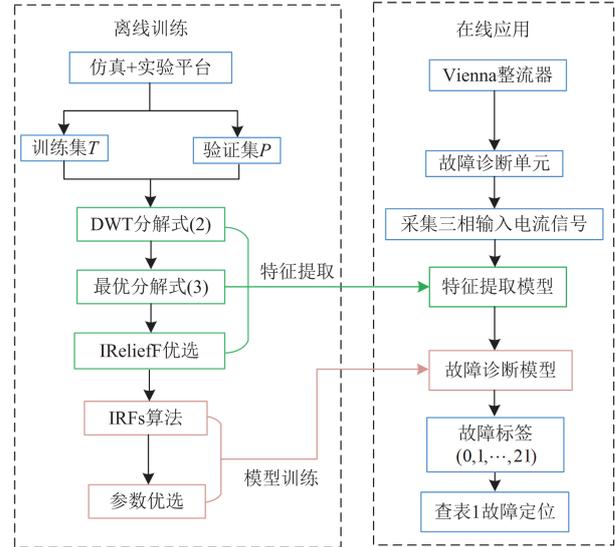


图 7 故障诊断流程

Fig. 7 Fault diagnosis process

## 3 实验研究与分析

### 3.1 数据库构建和模型训练

本文通过搭建 Vienna 整流器硬件实验平台和仿真模型构建开路故障数据库, 仿真参数与实验平台参数一致, 如表 3 所示。在实验过程中, 为保证所采集的数据能充分反映 Vienna 整流器实际运行工况, 数据获取考虑了输出直流母线电压幅值变化(540~820 V)、负载宽范围变化(0.1~10 kW)、叠加噪声和不同故障发生时刻等多种工况实验条件。同时, 为使所得实验数据符合实际故障发生时的规律, 实验数据获取方式为单次模拟故障后再启动再模拟<sup>[37]</sup>, 实验采样频率  $f_s$  为 800 kHz, 采样时间为

0.02 s。依据上述实验条件，得到了 35 200 组仿真数据集构成数据库  $D_f$  和 35 200 组实测数据集构成数据库  $D_p$ 。为验证方法的负载鲁棒性，依据负载功率范围将数据库分为 4 组(数据库 a~d)，如表 4 所示。

表 3 Vienna 整流器参数

Table 3 Parameters of Vienna rectifier

参数名称	数值
输入电压 $e_{ab}/V$	380
输入电源频率 $f/Hz$	50
额定母线电压 $V_{dc}/V$	600
额定功率 $P/kW$	10
开关频率 $f_s/kHz$	20
交流侧电感 $L/mH$	4.3
直流侧电容 $C/\mu F$	480
IGBT 型号	SKM100GB12T4

表 4 Vienna 整流器故障数据库

Table 4 Fault database of Vienna rectifier

数据库	训练集 (负载功率范围/kW)	测试集 (负载功率范围/kW)
数据库 a	0.1~2.5	2.5~10
数据库 b	2.5~5	0.1~2.5, 5~10
数据库 c	5~7.5	0.1~5, 7.5~10
数据库 d	7.5~10	0.1~7.5

考虑到变流器实际运用过程中的故障数据采集困难，故障诊断模型训练过程中的  $r_{pt}$  取值为 0.1，因此共 880 组数据作为验证数据集，剩余数据作为测试集，验证诊断模型的精度。同时采用 PSO 算法得到优化 RFs 故障分类器的超参数为  $r_{os} = 0.27$ 、 $N = 634$ 、 $m = 0.14$ 、 $v = 0.23$ 、 $\alpha = 0.61$ 。本文给出了图 8 所示的敏感超参数  $r_{os}$  和  $v$  变化下故障诊断准确率的变化情况，充分验证了超参数选用方法的有效性。

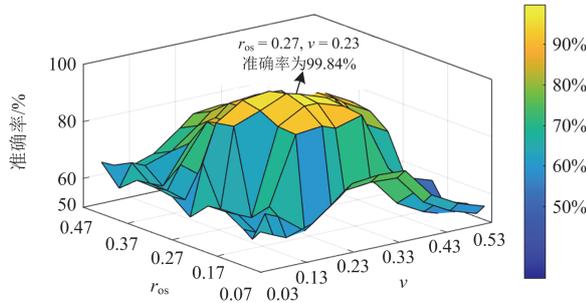


图 8 不同  $r_{os}$  和  $v$  下的平均诊断准确率

Fig. 8 Mean diagnostic accuracy at different  $r_{os}$  and  $v$

### 3.2 诊断精度与鲁棒性分析

#### 3.2.1 故障诊断精度对比实验

为了验证所提方法在 Vienna 整流器非平稳开路故障下的诊断精度，将本文所提出的诊断方法与 1D-CNN<sup>[19]</sup>、LSSVM<sup>[20]</sup>、HEL<sup>[21]</sup>、BN<sup>[22]</sup>和 RFs<sup>[30]</sup>等 5 种方法进行对比分析，对比方法的训练过程与本文保持一致。实验过程中统计 10 次实验结果的平均值进行对比分析，得到的结果如表 5 所示。相较于其他 5 种方法，所提方法具有最优的故障诊断精度(故障诊断准确率为 99.84%、精确率为 99.74%和召回率为 99.85%)。由此表明，所提方法较好地拟合了故障特征的概率分布，因此在面对具有周期非平稳特性的故障信号时，具有优越的故障诊断精度。

表 5 诊断精度对比结果

Table 5 Comparative results of diagnosis accuracy

对比方法	准确率/%	精确率/%	召回率/%
1D-CNN	95.79	96.10	95.45
LSSVM	96.64	95.74	94.55
HEL	94.73	93.09	95.59
BN	91.76	87.74	86.75
RFs	89.55	90.33	91.77
所提方法	99.84	99.74	99.85

为验证所提方法的计算复杂度，本文在 GPU: NVIDIA GeForce RTX 3090、Windows10 操作系统的 Pytorch 实验环境下统计了 1000 组样本的平均诊断时间，如表 6 所示。所提方法的诊断时间与 RFs 接近，由于 IRFs 算法决策树的并行计算特性，因此相较于 1D-CNN、LSSVM、HEL 和 BN 方法，所提方法的计算时间具有优势。

表 6 诊断时间对比结果

Table 6 Comparative results of diagnosis time

对比方法	1000 组样本的平均诊断时间/ $\mu s$
1D-CNN	10.23
LSSVM	6.87
HEL	8.73
BN	2.02
RFs	0.81
所提方法	0.83

#### 3.2.2 负载鲁棒性实验

为验证所提方法的负载鲁棒性，本文采用表 4 的数据库进行实验对比分析，统计 10 次实验结果的平均准确率如表 7 所示。再结合表 5 和表 7 可知，1D-CNN 和 LSSVM 在训练集和测试集负载范围不一致时故障诊断准确率下降了约 30%；HEL 和 BN 下降了 6%~10%，RFs 下降了 2%~6%；相较于其他 5 种方法，所提方法受负载影响较小，诊断准确率

下降幅度约为 0.28%。这是因为 1D-CNN 和 LSSVM 依赖于充足的故障数据, 当训练集负载功率范围有限时, 易出现过拟合; HEL、BN 和 RFs 一定程度避免了样本依赖, 但无法处理负载变化和周期非平稳变化。而所提方法采用 ODWT 聚焦故障信号的时频域细节, 并通过 IReliefF 优选得到重要故障特征, 可以有效应对负载变化, 且有限负载条件下训练的故障诊断模型能很好地推广到其他负载条件。

表 7 负载鲁棒性对比结果

Table 7 Comparative results of load robustness

对比方法	10 次实验结果的平均准确率/%			
	数据库 a	数据库 b	数据库 c	数据库 d
1D-CNN	62.26	65.45	65.27	68.16
LSSVM	67.55	64.42	68.31	69.27
HEL	87.16	84.35	88.34	87.27
BN	81.15	85.26	82.39	84.71
RFs	83.68	86.67	86.13	83.44
所提方法	99.56	99.62	99.75	99.67

### 3.2.3 传感器噪声和基准偏移的鲁棒性实验

为验证所提方法应对传感器噪声和基准偏移的鲁棒性, 将高斯白噪声叠加到测试集, 并统计 10 次实验的平均故障诊断准确率, 实验结果如表 8 所示。

$$F_B = m_{\text{ean}}(I - \tilde{I}) \quad (15)$$

$$S_{\text{NR}} = 10 \lg\left(\frac{P_{\text{signal}}}{P_{\text{noise}}}\right) \quad (16)$$

式中:  $I$  为实际电流;  $\tilde{I}$  为采样电流;  $m_{\text{ean}}(\cdot)$  为平均值;  $F_B$  为典型基偏;  $S_{\text{NR}}$  为信噪比;  $P_{\text{signal}}$  为信号功率;  $P_{\text{noise}}$  为噪声功率。

表 8 噪声鲁棒性对比结果

Table 8 Comparative results of noise robustness

对比方法	10 次实验的平均故障诊断准确率/%		
	$F_B = \pm 0.5 \text{ A}$	$F_B = \pm 1 \text{ A}$	$F_B = \pm 1.5 \text{ A}$
	$S_{\text{NR}} = 20 \text{ dB}$	$S_{\text{NR}} = 10 \text{ dB}$	$S_{\text{NR}} = 0 \text{ dB}$
1D-CNN	91.79	75.45	65.27
LSSVM	90.73	74.42	63.31
HEL	88.64	82.35	70.34
BN	87.76	81.26	71.39
RFs	83.55	80.67	73.13
所提方法	99.47	98.62	97.75

结合表 5 和表 8 分析可知, 所提方法和其他 5 种不同算法在含噪声测试集下的故障诊断准确率均有所降低, 且随着高斯白噪声的增强, 下降幅度越大。而相较于其他 5 种方法的下降幅度(4%~33.33%), 所提方法的下降幅度仅为 0.37%~2.09%, 且最低准确率仍然保持 97.75%。对比结果表明所提方法通过 IReliefF 和 IRFs, 显著增强了诊断模型对周期非平

稳特性下的传感器噪声和基准偏移的鲁棒性。

### 3.3 方法分析实验

为分析特征提取与特征优选方法(feature extraction optimization, FEP)和 IRFs 对增强鲁棒性的贡献, 本文在叠加噪声条件下进行不同组合方法的对比实验, 统计 10 次实验结果的平均故障诊断准确率如表 9 所示。相较于其他组合方法, 所提出 FEP + IRFs 的诊断准确率明显优于其他组合方法, 采用 FEP + RFs 或 FFT + IRFs 组合方法与 FFT + RFs 相比也同样具有优势。由此表明, 本文提出的特征提取优选方法和改进森林算法均可以增强故障诊断的鲁棒性。

表 9 组合方法对比结果

Table 9 Comparative results of combination methods

组合模式	10 次实验结果的平均故障诊断准确率/%		
	$F_B = \pm 0.5 \text{ A}$	$F_B = \pm 1 \text{ A}$	$F_B = \pm 1.5 \text{ A}$
	$S_{\text{NR}} = 20 \text{ dB}$	$S_{\text{NR}} = 10 \text{ dB}$	$S_{\text{NR}} = 0 \text{ dB}$
FFT + RFs	83.55	80.67	73.13
FEP + RFs	92.47	91.32	90.65
FFT + IRFs	91.57	89.66	87.56
FEP + IRFs	99.47	98.62	97.75

同时, 为分析 ODWT 和 IReliefF 对诊断鲁棒性的贡献, 本文通过组合不同的特征提取方法进行对比实验分析, 如表 10 所示。相较于 FFT+IRFs, 采用单一 ODWT 或 IReliefF 均能提高故障诊断准确率, 且所提 FEP + IRFs 组合方法的故障诊断准确率最高为 99.47%。由此表明, 所提 ODWT 和 IReliefF 方法均能够增强诊断模型的鲁棒性。

表 10 提取方法对比结果

Table 10 Comparative results of extraction methods

提取方法	10 次实验的平均故障诊断准确率/%		
	$F_B = \pm 0.5 \text{ A}$	$F_B = \pm 1 \text{ A}$	$F_B = \pm 1.5 \text{ A}$
	$S_{\text{NR}} = 20 \text{ dB}$	$S_{\text{NR}} = 10 \text{ dB}$	$S_{\text{NR}} = 0 \text{ dB}$
FFT + IRFs	91.57	89.66	87.56
ODWT + IRFs	97.61	96.71	94.56
IReliefF + IRFs	98.63	95.63	93.86
FEP + IRFs	99.47	98.62	97.75

为进一步分析所提方法的故障特征区分能力, 本文采用 t-SNE<sup>[38]</sup>降维技术(该方法将高维特征映射到二维空间, 用于可视化不同类别样本的特征空间分布, 其坐标轴单位为 1)将 Vienna 整流器单管/双管的 22 种原始故障特征和优选提取的重要故障特征映射到二维空间, 对比结果如图 9 所示。从图中的区分效果可以看出, Vienna 整流器开路故障电流信号的原始特征存在不同类别交叉重叠现象, 难

以准确区分故障类型。相比原始开路故障特征分布,所提方法得到的重要故障特征具有同类彼此接近、而不同类故障特征相互远离的显著特点,并且形成了清晰易于区分的不同故障分类边界。据此表明,所提方法得到的重要特征增强了对 Vienna 整流器开路故障周期非平稳变化的鲁棒性,从而有效提高了故障诊断模型精度。

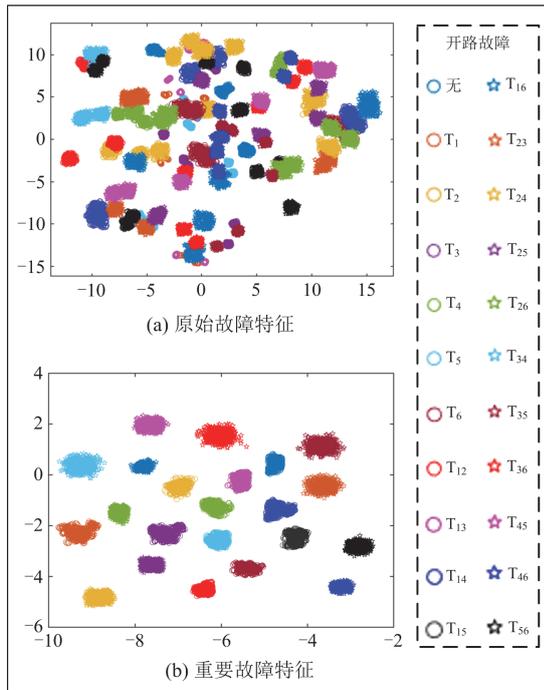


图 9 故障特征可视化  
Fig. 9 Visualization of fault features

### 3.4 在线故障诊断实验

为验证所提故障诊断模型在实际故障诊断应用场景中的实时性和鲁棒性,本文搭建了如图 10 所示的硬件实验平台进行在线故障诊断实验。该平台硬件基于 DSP 主控芯片(TMS320F28377s)和运行故障诊断模型的 FPGA (cyclone V); 利用三相可编程电源(Chroma61705)提供输入的交流电源;通过可编程电子负载(Chroma63205A)模拟负载变化;并利用高精度 4 通道示波器(TekMDO34)、高精度电流探头(TekTCP0150)进行信号采集。

#### 3.4.1 负载干扰下的在线故障诊断实验

为验证所提方法在负载干扰下的在线故障诊断实时性与鲁棒性,本文在图 10 所示的实验平台下设置  $T_2$  发生开路故障,在其故障发生后突增和突减负载,统计所提方法输出的故障诊断标签类型与容错控制命令时间,实验结果如图 11 所示。从图 11 可以看出,所提方法能够在负载突增或突减的情况下,快速而准确地定位故障并执行容错控制(约 0.02 s)。

表明所提方法在复杂工况下对负载干扰具有鲁棒性,确保故障诊断的可靠性。



图 10 实验平台  
Fig. 10 Experimental platform

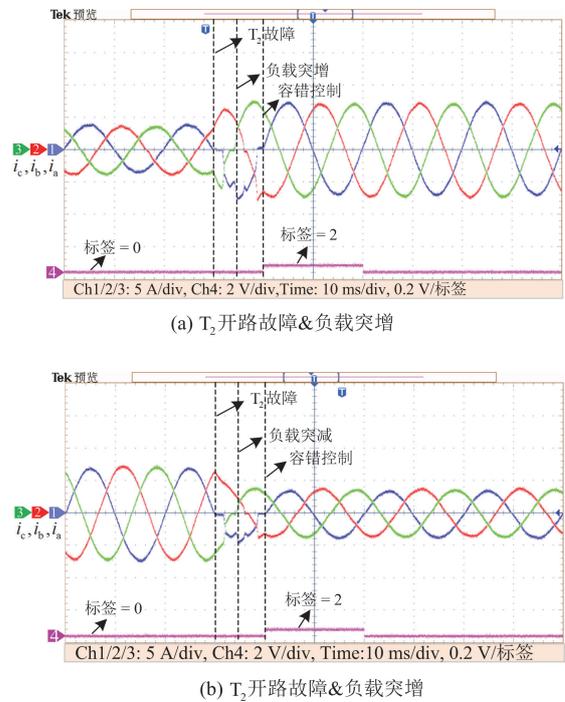


图 11 负载干扰下的在线鲁棒性实验

Fig. 11 Online robustness experiments under load disturbance

#### 3.4.2 噪声干扰下的在线故障诊断实验

为验证所提方法在传感器噪声和偏差下的在线故障诊断实时性与鲁棒性,本文分别在  $T_2$  &  $T_5$  和  $T_2$  &  $T_6$  故障信号中加入  $F_B = \pm 1 A$  和  $S_{NR} = 10 dB$  的噪声,并在图 10 所示的实验平台下统计所提方法输出的故障诊断标签类型与容错控制命令时间。

噪声和基准偏移干扰下的在线故障诊断实验结果如图 12 所示。从图中可以看出,所提出的方法能够在噪声明显覆盖故障特征的情况下,快速而准确地定位故障并执行容错控制(约 0.02 s)。由此表明,

所提出的 FEP 能够聚焦信号细节, 优选重要的故障特征, 并利用 IRFs 提高了决策树的鲁棒性, 因此所提方法对传感器噪声和基准偏移影响具有强鲁棒性。

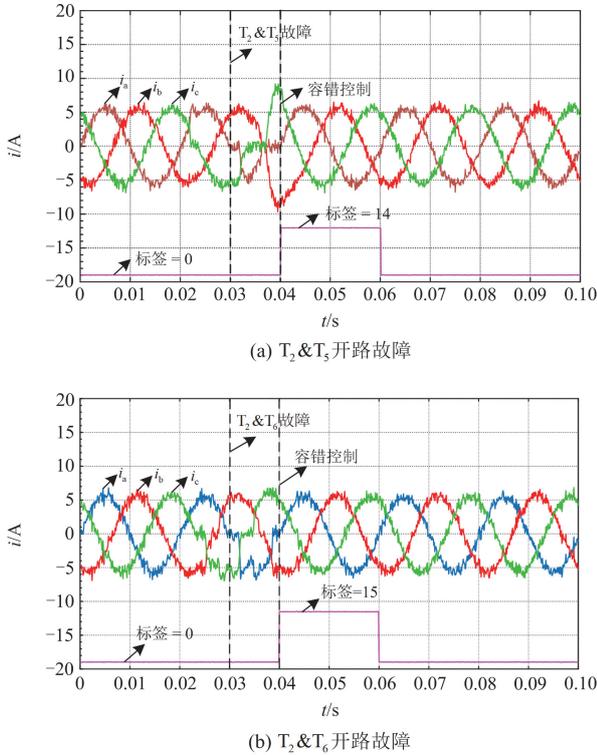


图 12 传感器噪声和基准偏移干扰下的在线鲁棒性实验  
Fig. 12 Online robustness experiments under sensor noise and reference offset interference

## 4 结论

本文提出一种基于特征提取和鲁棒精度加权的 RFs 故障诊断方法, 属于数据驱动的方法, 其适用性取决于故障信号的统计特性<sup>[39]</sup>, 并且所提诊断方法的有效性在搭建的 Vienna 整流器实验平台上得到了充分验证。在实际情况下, 多个 Vienna 整流器之间的运行工况和参数的差异客观存在, 但这些差异并不会改变 Vienna 整流器故障信号的统计特性。具体结论如下。

1) Vienna 整流器开路故障破坏了电流流通路径, 导致输入电流呈现零电流平台、不可控整流和无影响阶段交替的周期非平稳变化, 且该周期非平稳变化易受到负载扰动、传感器噪声和基准偏移影响, 显著降低了机器学习模型的故障诊断精度。

2) 所提出的特征提取与优选方法, 采用 ODWT 聚焦故障电流信号的时频域细节, 并通过 IReliefF 算法优选具有鲁棒周期非平稳变化能力的重要故障特征, 增强了故障诊断模型的区分能力。

3) 基于误差分析理论, IRFs 通过 OOB 数据的噪声鲁棒测试, 调整决策树的投票权重, 进一步增强了故障诊断模型在负载变化、传感器噪声和基准偏移等不确定性干扰下的精度与鲁棒性。

4) 所提方法在应用于多个 Vienna 整流器故障诊断的时候, 只需针对具体的对象进行数据采集和模型训练, 就能获得有效的故障诊断效果。

## 参考文献

- [1] PEI Y, TANG Y, HU M, et al. Switching loss-reduced space-vector DPWM for three-phase Vienna rectifier considering neutral-point voltage fluctuation[J]. IEEE Transactions on Power Electronics, 2024, 39(12): 16231-16241.
- [2] 范家宁, 马辉, 何奇, 等. 三相电压型 VIENNA 整流器建模及稳定性分析[J]. 电力科学与技术学报, 2024, 39(1): 243-250.  
FAN Jianing, MA Hui, HE Qi, et al. Modeling and stability analysis of three-phase voltage source VIENNA rectifier[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 243-250.
- [3] 姜卫东, 张庆岩, 刘圣宇, 等. 适用于双负载模式的 Vienna 整流器调制方法[J]. 电力系统自动化, 2023, 47(17): 160-168.  
JIANG Weidong, ZHANG Qingyan, LIU Shengyu, et al. Modulation method for vienna rectifier in dual load mode[J]. Automation of Electric Power Systems, 2023, 47(17): 160-168.
- [4] 陈杰, 沈禹廷, 沈佳茜, 等. 三相 VIENNA 整流器的混合空间矢量脉宽调制策略[J]. 电工技术学报, 2021, 36(增刊 2): 665-675.  
CHEN Jie, SHEN Yuting, SHEN Jiaqian, et al. Hybrid space vector pulse width modulation strategy for three-phase Vienna rectifier[J]. Transactions of China Electrotechnical Society, 2021, 36(S2): 665-675.
- [5] LU B, SHARMA S K. A literature review of IGBT fault diagnostic and protection methods for power inverters[J]. IEEE Transactions on Industry Applications, 2009, 45(5): 1770-1777.
- [6] 姚芳, 王刘浏, 唐圣学, 等. 基于瞬态电流角度的维也纳整流器单管开路故障的在线辨识[J]. 高电压技术, 2021, 47(1): 111-117.  
YAO Fang, WANG Liuliu, TANG Shengxue, et al. Online identification method for Vienna rectifier single switch open-fault based on transient current angle information[J]. High Voltage Engineering, 2021, 47(1): 111-117.
- [7] 王海亮, 王兴贵, 李锦键, 等. 基于改进支持向量机的 MMC-MG 系统桥臂故障诊断[J]. 电力系统保护与控制

- 制, 2023, 51(7): 1-13.
- WANG Hailiang, WANG Xingguai, LI Jinjian, et al. Bridge arm fault diagnosis of the MMC-MG system based on an improved support vector machine[J]. *Power System Protection and Control*, 2023, 51(7): 1-13.
- [8] 马呈瑶, 赵鲁, 范恩泽, 等. 应用于高频辅助变流器的 DBSRC 变换器 IGBT 开路故障分析及容错运行研究[J]. *电力系统保护与控制*, 2023, 51(19): 67-80.
- MA Chengyao, ZHAO Lu, FAN Enze, et al. IGBT open-circuit fault analysis and fault-tolerant operation research of DBSRC converter applied to high-frequency auxiliary converter[J]. *Power System Protection and Control*, 2023, 51(19): 67-80.
- [9] 许水清, 黄文展, 何怡刚, 等. 基于自适应滑模观测器的中点钳位型三电平并网逆变器开路故障诊断[J]. *电工技术学报*, 2023, 38(4): 1010-1022.
- XU Shuiqing, HUANG Wenzhan, HE Yigang, et al. Open-circuit fault diagnosis method of neutral point clamped three-level grid-connected inverter based on adaptive sliding mode observer[J]. *Transactions of China Electrotechnical Society*, 2023, 38(4): 1010-1022.
- [10] POON J, JAIN P, KONSTANTAKOPOULOS I C, et al. Model-based fault detection and identification for switching power converters[J]. *IEEE Transactions on Power Electronics*, 2016, 32(2): 1419-1430.
- [11] 张潇丹, 段斌, 刘昌杰, 等. 基于本体追踪的永磁同步电机驱动系统开路故障诊断方法[J]. *电工技术学报*, 2022, 37(13): 3341-3349, 3360.
- ZHANG Xiaodan, DUAN Bin, LIU Changjie, et al. Open circuit fault diagnosis method for permanent magnet synchronous machine drive system based on ontology tracking[J]. *Transactions of China Electrotechnical Society*, 2022, 37(13): 3341-3349, 3360.
- [12] HUANG W, DU J, HUA W, et al. An open-circuit fault diagnosis method for PMSM drives using symmetrical and DC components[J]. *Chinese Journal of Electrical Engineering*, 2021, 7(3): 124-135.
- [13] ATTOUI I, OMEIRI A. Fault diagnosis of an induction generator in a wind energy conversion system using signal processing techniques[J]. *Electric Power Components and Systems*, 2015, 43(20): 2262-2275.
- [14] HUANG W, DU J, HUA W, et al. Current-based open-circuit fault diagnosis for PMSM drives with model predictive control[J]. *IEEE Transactions on Power Electronics*, 2021, 36(9): 10695-10704.
- [15] CHENG Y, DONG W, GAO F, et al. Open-circuit fault diagnosis of traction inverter based on compressed sensing theory[J]. *Chinese Journal of Electrical Engineering*, 2020, 6(1): 52-60.
- [16] JAMES J Q, HOU Y, LAM A Y S, et al. Intelligent fault detection scheme for microgrids with wavelet-based deep neural networks[J]. *IEEE Transactions on Smart Grid*, 2017, 10(2): 1694-1703.
- [17] XIA Y, XU Y. A transferrable data-driven method for IGBT open-circuit fault diagnosis in three-phase inverters[J]. *IEEE Transactions on Power Electronics*, 2021, 36(12): 13478-13488.
- [18] YU W, ZHAO C. Broad convolutional neural network based industrial process fault diagnosis with incremental learning capability[J]. *IEEE Transactions on Industrial Electronics*, 2019, 67(6): 5081-5091.
- [19] YUAN W, LI Z, HE Y, et al. Open-circuit fault diagnosis of NPC inverter based on improved 1-D CNN network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-11.
- [20] SHI T, HE Y, WANG T, et al. Open switch fault diagnosis method for PWM voltage source rectifier based on deep learning approach[J]. *IEEE Access*, 2019, 7: 66595-66608.
- [21] XIA Y, XU Y, GOU B. A data-driven method for IGBT open-circuit fault diagnosis based on hybrid ensemble learning and sliding-window classification[J]. *IEEE Transactions on Industrial Informatics*, 2019, 16(8): 5223-5233.
- [22] CAI B, ZHAO Y, LIU H, et al. A data-driven fault diagnosis methodology in three-phase inverters for PMSM drive systems[J]. *IEEE Transactions on Power Electronics*, 2016, 32(7): 5590-5600.
- [23] FANG H, DENG J, ZHAO B, et al. LEFE-Net: a lightweight efficient feature extraction network with strong robustness for bearing fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-11.
- [24] 沈赋, 张微, 徐潇源, 等. 基于随机森林和最大互信息系数关键特征选择的配电网拓扑辨识研究[J]. *电力系统保护与控制*, 2024, 52(17): 1-11.
- SHEN Fu, ZHANG Wei, XU Xiaoyuan, et al. Topological identification of distribution networks based on key feature selection using RF and MIC[J]. *Power System Protection and Control*, 2024, 52(17): 1-11.
- [25] 王桐, 史雯, 石浩瀚, 等. 基于平稳小波变换的光伏直流串联电弧故障检测[J]. *电力系统保护与控制*, 2024, 52(12): 82-93.
- WANG Tong, SHI Wen, SHI Haoyuan, et al. Photovoltaic DC series arc fault detection based on stationary wavelet transform[J]. *Power System Protection and Control*, 2024, 52(12): 82-93.

- [26] YIN Z, WANG L, ZHANG Y, et al. A novel arc fault detection method integrated random forest, improved multi-scale permutation entropy and wavelet packet transform[J]. *Electronics*, 2019, 8(4).
- [27] LI H, HU G, LI J, et al. Intelligent fault diagnosis for large-scale rotating machines using binarized deep neural networks and random forests[J]. *IEEE Transactions on Automation Science and Engineering*, 2021, 19(2): 1109-1119.
- [28] KOU L, LIU C, CAI G, et al. Fault diagnosis for open-circuit faults in NPC inverter based on knowledge-driven and data-driven approaches[J]. *IET Power Electronics*, 2020, 13(6): 1236-1245.
- [29] KOU L, LIU C, CAI G, et al. Data-driven design of fault diagnosis for three-phase PWM rectifier using random forests technique with transient synthetic features[J]. *IET Power Electronics*, 2020, 13(16): 3571-3579.
- [30] LI B, DELPHA C, DIALLO D, et al. Application of artificial neural networks to photovoltaic fault detection and diagnosis: a review[J]. *Renewable and Sustainable Energy Reviews*, 2021, 138.
- [31] 邹甲, 王聪, 程红, 等. 三相线电压级联 VIENNA 变换器调制及直流侧电压控制[J]. *电工技术学报*, 2018, 33(16): 3835-3844.  
ZOU Jia, WANG Cong, CHENG Hong, et al. Research on modulation strategy and balance control for DC-link voltages in triple line-voltage cascaded VIENNA converter[J]. *Transactions of China Electrotechnical Society*, 2018, 33(16): 3835-3844.
- [32] HUANG Z, WANG Z, LIU L. A practical fault diagnosis algorithm based on aperiodic corrected-second low-frequency processing for microgrid inverter[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(7): 3889-3898.
- [33] ROBNIK-ŠIKONJA M, KONONENKO I. Theoretical and empirical analysis of ReliefF and RReliefF[J]. *Machine Learning*, 2003, 53: 23-69.
- [34] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45: 5-32.
- [35] MANSOURI M, FEZAI R, TRABELSI M, et al. Reduced Gaussian process regression based random forest approach for fault diagnosis of wind energy conversion systems[J]. *IET Renewable Power Generation*, 2021, 15(15): 3612-3621.
- [36] HAN S, KIM H. On the optimal size of candidate feature set in random forest[J]. *Applied Sciences*, 2019, 9(5).
- [37] YAN H, PENG Y, SHANG W, et al. Open-circuit fault diagnosis in voltage source inverter for motor drive by using deep neural network[J]. *Engineering Applications of Artificial Intelligence*, 2023, 120.
- [38] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9(11).
- [39] AVIÑA-CORRAL V, DE JESUS RANGEL-MAGDALENO J, BARRON-ZAMBRANO J H, et al. Review of fault detection techniques in power converters: fault analysis and diagnostic methodologies[J]. *Measurement*, 2024, 234.

收稿日期: 2024-07-15; 修回日期: 2024-10-08

作者简介:

孙章(1986—), 男, 通信作者, 博士研究生, 研究方向为电能变换控制技术、智能控制技术等; E-mail: 383623076@qq.com

金炜东(1959—), 男, 博士, 教授, 研究方向为人工智能算法、预测控制与智能控制等。E-mail: wdjin@home.swjtu.edu.cn

(编辑 魏小丽)