

# 基于GAWOA优化ELM的风机变流器故障诊断\*

许如远, 马萍<sup>†</sup>

(新疆大学 电气工程学院, 新疆 乌鲁木齐 830017)

**摘要:** 为提高双馈异步风力发电机变流器的开路故障诊断准确率, 提出一种基于全局自适应鲸鱼优化算法优化极限学习机的故障诊断方法. 首先, 建立双馈异步风力发电机(DFIG)并网模型, 采集网侧变流器故障状态下的三相线电压信号. 其次, 对采集的电压信号进行快速傅里叶变换, 再将三相线电压的不同谐波分量的频率幅值和直流分量重构成特征向量, 为去除部分冗余特征, 利用邻域保持投影对特征向量进行降维. 最后, 利用全局自适应鲸鱼优化算法优化的极限学习机(GAWOA-ELM)对变流器故障进行诊断. 使用不同方法对不同信噪比下的变流器故障进行诊断分析, 验证了本文所提方法的有效性和鲁棒性.

**关键词:** 双馈感应电机; 变流器; 故障诊断; 全局自适应鲸鱼算法; 极限学习机

**DOI:** 10.13568/j.cnki.651094.651316.2021.07.08.0001

**中图分类号:** TM46 **文献标识码:** A **文章编号:** 2096-7675(2022)03-0377-08

**引文格式:** 许如远, 马萍. 基于GAWOA优化ELM的风机变流器故障诊断[J]. 新疆大学学报(自然科学版)(中英文), 2022, 39(3): 377-384.

**英文引文格式:** XU Ruyuan, MA Ping. Fault diagnosis of wind turbine converter based on GAWOA-ELM[J]. Journal of Xinjiang University(Natural Science Edition in Chinese and English), 2022, 39(3): 377-384.

## Fault Diagnosis of Wind Turbine Converter Based on GAWOA-ELM

XU Ruyuan, MA Ping

(School of Electrical Engineering, Xinjiang University, Urumqi Xinjiang 830017, China)

**Abstract:** In order to improve the accuracy of the open-circuit fault diagnosis of the double-fed asynchronous wind turbine converter, a fault diagnosis method based on the global adaptive whale optimization algorithm to optimize the extreme learning machine is proposed. Firstly, establish a grid-connected model of doubly-fed induction generator(DFIG), and collect the three-phase line voltage signal under the fault state of the grid-side converter. Secondly, fast Fourier transform is performed on the collected voltage signal, and then the frequency amplitude of the different harmonic components of the three-phase line voltage and the DC component are reconstructed into a feature vector. In order to remove some redundant features, use the neighborhood to maintain the projection pair, the feature vector is dimensionally reduced. Finally, an extreme learning machine optimized by the global adaptive whale optimization algorithm(GAWOA-ELM) is used to diagnose the faults of the converter. Different methods are used to diagnose and analyze converter faults under different signal-to-noise ratios, verifying the effectiveness and robustness of the method proposed in this paper.

**Key words:** doubly fed induction generator; electric converters; fault diagnosis; global adaptive whale optimization algorithm; extreme learning machine

## 0 引言

变流器是双馈异步风力发电机组的关键部件, 极易发生故障<sup>[1-2]</sup>. 变流器开关管的故障会导致系统不能正常工作, 甚至会引起其他设备故障进而发生二次故障, 导致机组停机. 有效的诊断方法可以及时发现变流器故障, 避免二次故障的发生, 减少风电机组运行成本<sup>[3]</sup>.

\* 收稿日期: 2021-07-08

基金项目: 国家自然科学基金(52065064; 51967019); 天山雪松计划(2020XS03); 天山青年计划(2020Q066).

作者简介: 许如远(1995-), 男, 硕士生, 从事变流器故障诊断的研究, E-mail: ruyuan\_xu@qq.com.

<sup>†</sup> 通讯作者: 马萍(1994-), 女, 副教授, 硕士生导师, 主要从事电力系统故障诊断与状态监测的研究, E-mail: maping@xju.edu.cn.

目前,国内外学者已经提出了一些变流器IGBT模块故障的诊断方法,对IGBT模块进行了有效诊断<sup>[4-6]</sup>.文献[7]采集故障状态下的网侧变流器三相线电压作为信号源,对电压信号进行集合经验模态分解,将不同模态函数的范数熵作为故障特征,利用支持向量机(Support Vector Machine, SVM)对不同故障模式进行分类,该方法能有效诊断不同故障模式下的变流器故障;文献[8]以电机定子电流和机械转速为输出,构建递归解耦结构,通过非线性观测器合成 $dq$ 轴方向的残差,实现了隔离多个同时发生的故障的目的,但系统变化易影响模型结构,对模型准确性有很大影响;文献[9]利用变流器归一化的相电流平均值和归一化电流作为故障特征向量,对变流器进行故障诊断,该方法具有较强的鲁棒性和实时诊断能力,但没有考虑大量随机噪声对模型诊断准确性的影响;文献[10]利用电机相电流和参考相电流信号偏差,实现了变流器故障诊断;文献[11]利用BP(Back-Propagation)神经网络对故障电压信号重构的特征向量进行分类,提高了故障分类精度;文献[12]通过计算电压信号小波变换的总能量和总熵确定故障类型,该方法能同时检测变换器转子侧和电网侧的故障;文献[13]利用电流信号与振动信号的关联机制,融合电流和振动信号作为故障特征向量,此方法只适用于单个IGBT模块开路故障诊断.

本文以网侧变流器线电压为信号源,对故障电压信号进行快速傅里叶变换(Fast Fourier Transform, FFT),将频谱中直流分量幅值和谐波分量频率幅值重构成故障特征向量.利用邻域保持投影(Neighborhood Preserving Embedding, NPE)对数据进行处理,使得到的故障特征向量保留原始数据特征且去除数据中的冗余信息,通过全局自适应鲸鱼算法(Global Adaptive Whale Optimization Algorithm, GAWOA)对极限学习机(Extreme Learning Machine, ELM)的权值和阈值进行优化,得到较为精确的故障诊断模型.实验结果表明:GAWOA-ELM模型能有效诊断单IGBT模块和双IGBT模块开路故障,且具有较好的鲁棒性.

## 1 双馈风电机组模型建立

### 1.1 双馈风力发电机组模型建立

双馈风电机组由3个部分组成:双馈风力发电机(Doubly-Fed Induction Generator, DFIG)、转子侧变流器(Rotor Side Converter, RSC)、网侧变流器(Grid Side Converter, GSC),其拓扑如图1所示. RSC跟踪最大风能,实现变速恒频, GSC保持直流侧电压恒定,防止电网谐波.

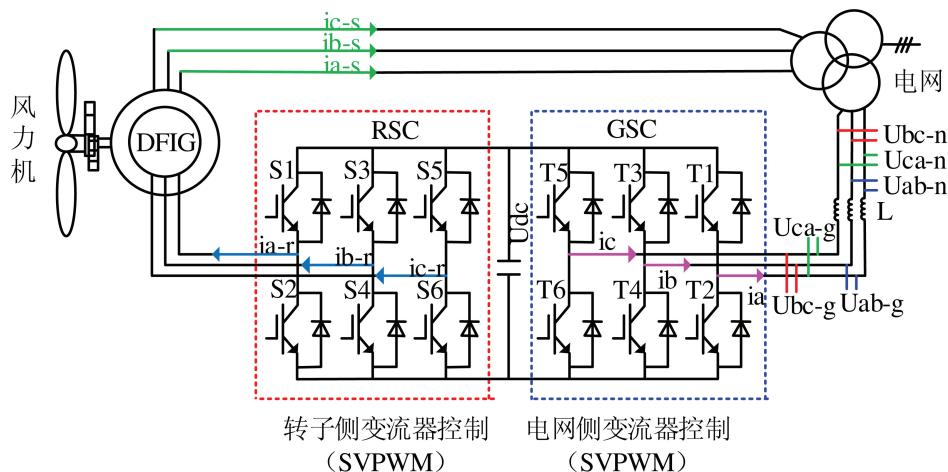


图1 双馈风力发电系统的拓扑结构

忽略发电机的高次谐波分量、磁路饱和,各物理量按照发电机惯例选取,电机在 $d-q$ 坐标系下的电压方程、磁链方程、发电机功率方程<sup>[14-16]</sup>可表示为:

$$\begin{cases} u_{ds} = R_s i_{ds} + \frac{d\psi_{ds}}{dt} - \omega_1 \psi_{qs} \\ u_{qs} = R_s i_{qs} + \frac{d\psi_{qs}}{dt} + \omega_1 \psi_{ds} \\ u_{dr} = R_r i_{dr} + \frac{d\psi_{dr}}{dt} - \omega_s \psi_{qr} \\ u_{qr} = R_r i_{qr} + \frac{d\psi_{qr}}{dt} + \omega_s \psi_{dr} \end{cases} \quad (1)$$

$$\begin{cases} \psi_{ds} = L_s i_{ds} + L_m i_{dr} \\ \psi_{qs} = L_s i_{qs} + L_m i_{qr} \\ \psi_{dr} = L_r i_{dr} + L_m i_{ds} \\ \psi_{qr} = L_r i_{qr} + L_m i_{qs} \end{cases} \quad (2)$$

$$\begin{cases} P_s = \frac{3}{2} (u_{ds} i_{ds} + u_{qs} i_{qs}) \\ Q_s = \frac{3}{2} (u_{qs} i_{ds} + u_{ds} i_{qs}) \end{cases} \quad (3)$$

式中:  $R_s$ 、 $R_r$ 为定、转子绕组等效电阻;  $L_s$ 、 $L_r$ 、 $L_m$ 为 $d$ 、 $q$ 轴定、转子绕组自感和互感;  $u_{ds}$ 、 $u_{qs}$ 、 $u_{dr}$ 、 $u_{qr}$ 分别为定、转子 $d$ 、 $q$ 轴电压;  $i_{ds}$ 、 $i_{qs}$ 、 $i_{dr}$ 、 $i_{qr}$ 分别为定、转子 $d$ 、 $q$ 轴电流;  $\psi_{ds}$ 、 $\psi_{qs}$ 、 $\psi_{dr}$ 、 $\psi_{qr}$ 分别为定、转子 $d$ 、 $q$ 轴磁链;  $\omega_1$ 、 $\omega_s$ 为同步转速和滑差角速度;  $P_s$ 、 $Q_s$ 为发电机有功功率和无功功率. 以 $d$ 轴为定子磁链方向, 根据定子总磁链与端电压矢量垂直的关系, 则 $\psi_{ds} = \psi_s$ 、 $\psi_{qs} = 0$ . 此时式(2)可表示为:

$$\begin{cases} i_{ds} = \frac{\psi_s - L_m}{L_s} \\ i_{qs} = -\frac{L_m i_{qr}}{L_s} \end{cases} \quad (4)$$

将式(4)带入式(1)得:

$$\begin{cases} u_{ds} = 0 \\ u_{qs} = U_s \end{cases} \quad (5)$$

再将式(4)、式(5)带入式(3), 式(3)即可转化为:

$$\begin{cases} P_s = -\frac{3}{2} U_s \frac{L_m}{L_s} i_{qr} \\ Q_s = \frac{3}{2} \left( \frac{U_s^2}{\omega_1 L_s} - \frac{L_m}{L_s} U_s i_{dr} \right) \end{cases} \quad (6)$$

由式(6)可知,  $P_s$ 与 $i_{qr}$ 成线性关系,  $Q_s$ 与 $i_{dr}$ 成线性关系, 且 $i_{dr}$ 和 $i_{qr}$ 无耦合关系, 则参考电压信号可作为控制有功、无功功率的PWM矢量控制量. 将式(4)带入式(2)得:

$$\begin{cases} \psi_{dr} = \frac{L_m}{L_s} \psi_s + \left( L_r - \frac{L_m^2}{L_s} \right) i_{dr} \\ \psi_{qr} = \left( L_r - \frac{L_m^2}{L_s} \right) i_{qr} \end{cases} \quad (7)$$

将式(7)带入式(1)得转子电压方程如下:

$$\begin{cases} u_{dr} = R_r i_{dr} + \left( L_r - \frac{L_m^2}{L_s} \right) \frac{di_{dr}}{dt} - \left( L_r - \frac{L_m^2}{L_s} \right) \omega_s i_{qr} \\ u_{qr} = R_r i_{qr} + \left( L_r - \frac{L_m^2}{L_s} \right) \frac{di_{qr}}{dt} + \left( L_r - \frac{L_m^2}{L_s} \right) \omega_s i_{ds} + \frac{L_m \psi_s}{L_s} \omega_s \end{cases} \quad (8)$$

由式(8)可知, 通过转子电压控制有功、无功功率. 设电网电压矢量 $u_s$ 的参考方向为 $d$ 轴方向, 则 $u_s$ 满足:

$$\begin{cases} u_d = u_s \\ u_q = 0 \end{cases} \quad (9)$$

网侧变流器功率方程为:

$$\begin{cases} P_g = u_d i_d + u_q i_q = u_s i_d \\ Q_g = u_q i_d - u_d i_q = -u_s i_q \end{cases} \quad (10)$$

式中:  $P_g$ 、 $Q_g$ 为网侧变流器有功功率和无功功率. 由于电网电压基本保持不变, 所以 $P_g$ 与 $i_d$ 成线性关系,  $Q_g$ 与 $i_q$ 成线性关系, 通过 $i_d$ 、 $i_q$ 控制有功功率和交流侧电压、电流.

## 1.2 网侧变流器IGBT模块故障类型

以电网侧变流器的IGBT模块为研究对象. 考虑同一桥臂和不同桥臂上的IGBT故障, 对变流器的6只IGBT(IGBT用Ti表示)模块进行分析, 单IGBT模块故障6种, 双IGBT模块故障15种(三个IGBT模块故障较少), 共计22种模式(1种正常运行状态, 21种故障状态), 故障编码见表1.

表 1 IGBT故障编码

编号	故障类型	故障标签	编号	故障类型	故障标签
1	正常	000000	12	T1、T5	100010
2	T1	100000	13	T3、T5	001010
3	T2	010000	14	T2、T4	010100
4	T3	001000	15	T2、T6	010001
5	T4	000100	16	T4、T6	000101
6	T5	000010	17	T1、T4	100100
7	T6	000001	18	T1、T6	100001
8	T1、T2	001000	19	T3、T2	010001
9	T3、T4	001001	20	T3、T6	001001
10	T5、T6	000011	21	T5、T2	010010
11	T1、T3	101000	22	T5、T4	000110

## 2 基于自适应鲸鱼算法优化的改进极限学习机

### 2.1 极限学习机

ELM是一种单隐层神经网络,具有求解速度更快、学习效率更高、适应能力更强的特点<sup>[17-18]</sup>.设有 $n$ 个不同样本 $(x_i, t_i)$ ,对于 $l$ 个节点的隐含层,ELM网络模型可表示为:

$$\sum_{k=1}^l \beta_k f(w_k * x_j + b_k) = y_j \quad (11)$$

式中: $w_k$ 为输入权值向量, $b_k$ 为隐含层的阈值向量, $\beta_k$ 为输出权值向量.当激活函数 $f$ 逼近任意 $n$ 个样本时,有:

$$\sum_{k=1}^l \beta_k f(w_k * x_j + b_k) = t_j \quad (12)$$

$$\text{令 } H = \begin{pmatrix} f(w_1 x_1 + b_1) & \dots & f(w_l x_1 + b_l) \\ \vdots & \ddots & \vdots \\ f(w_1 x_n + b_1) & \dots & f(w_l x_n + b_l) \end{pmatrix}, \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_l^T \end{bmatrix}_{l \times m}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_l^T \end{bmatrix}_{l \times m}, \text{ 则式 (12) 可化简为求解下}$$

列方程的最小二乘解:

$$\|H\hat{\beta} - T\| = \min_{\beta} \|H\hat{\beta} - T\| \quad (13)$$

其解为 $\hat{\beta} = H^+ T$ , $H^+$ 为隐含输出矩阵 $H$ 的Moore-Penrose广义逆.由于ELM神经网络的 $w_k$ 和 $b_k$ 均为随机向量,因此该神经网络参数并非最优值,需要对ELM模型进一步优化.

### 2.2 鲸鱼优化算法

鲸鱼算法具有搜索能力强、参数设置少、操作简单的特点<sup>[19-20]</sup>,主要包括两个阶段,具体描述如下:

#### (1) 初始搜索阶段

初始阶段,每条鲸鱼位置更新依据如下:

$$\begin{cases} \vec{X}(t+1) = \vec{X}_{rand}(t) - \vec{A} * \vec{D} \\ \vec{D} = |\vec{C} * \vec{X}_{rand}(t) - \vec{X}(t)| \end{cases} \quad (14)$$

式中: $t$ 表示当前迭代次数, $\vec{X}_{rand}(t)$ 为初始鲸鱼个体位置的向量,向量系数 $\vec{A} = 2ar_1 - a$ 、 $\vec{C} = 2r_2$ ,随机向量 $r_1$ 、 $r_2$ 取值范围为 $[0,1]$ ,收敛因子 $a = 2 - 2t/t_{max}$ , $t_{max}$ 为最大迭代次数.当 $|\vec{A}| \leq 1$ 时,算法进入包围攻击阶段.

#### (2) 包围攻击阶段

鲸鱼进入包围攻击阶段时,鲸鱼个体位置更新公式如下:

$$\vec{X}(t+1) = \begin{cases} \vec{D}_{best} * e^{bl} * \cos(2\pi l) + \omega \vec{X}(t), p < 0.5 \\ \omega \vec{X}_{best}(t) - \vec{A} * \vec{D}, p > 0.5 \end{cases} \quad (15)$$

式中:  $\vec{X}_{best}(t)$ 、 $\vec{D}_{best}$  分别为当前种群最优解的位置向量和猎物到最优鲸鱼个体的距离,  $\vec{X}(t)$  为当前个体的位置向量,  $\omega$  为权重常量,  $\omega=1$ ,  $b$  为常量系数,  $l$  是  $[-1,1]$  之间的随机数,  $p$  是在  $[0,1]$  上的均匀分布.

### 2.3 全局自适应鲸鱼优化算法

由式 (15) 可知, WOA 在包围攻击过程中的权重为 1, 这种权重恒定不变的搜索速度降低了算法的效率, 为了提高 WOA 的全局搜索能力, GAWOA 在 WOA 的基础上引入自适应权重  $\omega$ , 其计算公式为:

$$\omega = 1 - \frac{e^{t/t_{max}} - 1}{e - 1} \tag{16}$$

式中:  $t$  为当前迭代次数,  $t_{max}$  为最大迭代次数. 由式 (16) 可知,  $\omega$  会随着迭代次数的增大而减小, 提高算法前期的搜索速度和后期寻优精度. 虽然引入自适应权重能提高算法的全局搜索能力, 但算法的最优解只是随着迭代过程而更新, 容易忽略当前最优解的邻域部分的可能最优解, 引入邻域扰动机制可以对最优解的邻域部分进行搜索, 避免算法进入早熟, 寻找到更好的全局值. 邻域扰动公式如下:

$$\tilde{X}(t) = \vec{X}_{best}(t) + 0.1 * (2rand - 1) \vec{X}_{best}(t) \tag{17}$$

式中:  $rand$  为  $[0,1]$  的随机数,  $\tilde{X}(t)$  为邻域内的可能位置. 通过计算  $\tilde{X}(t)$  和  $\vec{X}_{best}(t)$  的适应度值判断是否保留当前位置. 为确定最佳的 ELM 网络结构, 选取不同的输入层节点  $n$ 、隐含层节点  $l$  和激活函数对测试集进行分类, 最终确定当  $n=l=300$  且激活函数为 “Sigmoid” 时, 测试集分类正确率最高.

## 3 风电机组变流器故障特征提取

本文选取故障状态下的网侧变流器三相线电压  $U_{ab-g}$ 、 $U_{bc-g}$ 、 $U_{ca-g}$  为故障信号, 采样频率设置为 5 000 Hz, 采样点数为 2 500. 每类故障三相线电压信号构成一个  $3 \times 2\ 500$  的矩阵样本, 样本数据集大小为 80, 故障特征提取步骤如下:

(1) 采集 22 种故障线电压信号并对其进行 FFT 变换, 得到其频谱图. 针对每一种故障, 对  $U_{ab-g}$  线电压信号频谱的频率幅值进行等间隔采样. 采样间隔为 5, 得到 500 个频率幅值. 同理, 可对  $U_{bc-g}$ 、 $U_{ca-g}$  线电压信号频谱进行提取, 将提取到的三相线电压频率幅值进行重构, 构成长度为 1 500 的初始故障特征向量.

(2) 步骤 1 中的初始故障特征向量由故障三相线电压信号频谱图中谐波分量频率幅值构成. 不同 IGBT 模块故障时的直流分量的相位角有明显差异, 其相角差为  $\pi$ . 当 T1 故障时, 三相线电压信号中直流分量幅值分别为 0、-31.42、9.50, 如图 2 (a) 所示; 当 T1、T2 同时故障时, 直流分量幅值分别为 0、-37.7、-47.12, 如图 2 (b) 所示. 因此, 三相线电压信号中直流分量的幅值可作为故障特征添加到故障特征向量中, 得到长度为 1 503 的特征向量.

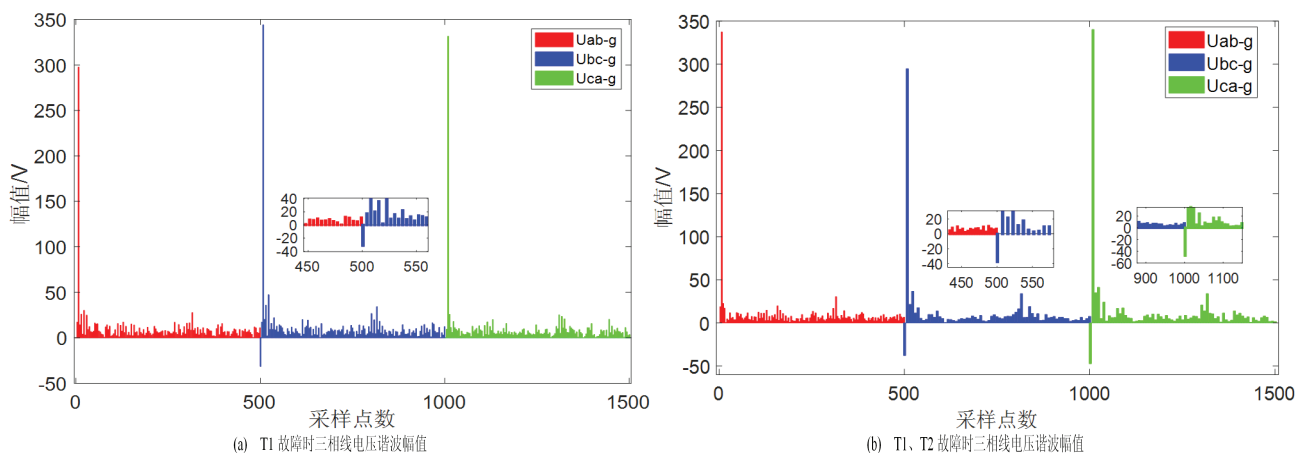


图 2 故障时三相线电压谐波幅值

(3) 针对故障特征向量维度太高、存在冗余特征的问题, 利用 NPE 对特征向量进行降维, 得到长度为 300 的故障特征向量. 对于每种故障, 采集 80 个样本, 其最终的故障特征样本维度为  $80 \times 300$ .

根据以上故障特征处理和诊断过程,提取22类初始故障特征,将降维后的特征向量输入GAWOA-ELM模型中进行分类,变流器故障诊断流程如图3所示.

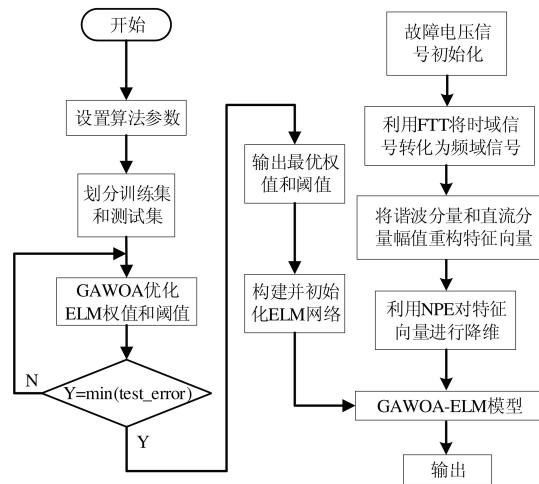


图 3 风机变流器故障诊断流程框图

### 4 实验分析

本文利用MATLAB/Simulink环境搭建了DFIG-无穷大系统模型,风电系统仿真参数见表2.模拟实验的采样频率为5 kHz,采样时间为0.5 s,风速间隔为0.062 5 m·s<sup>-1</sup>.

表 2 风电系统仿真参数

风机参数	取值	风机参数	取值
额定功率/MW	1.5	转子电阻/pu	0.016
额定电压/V	575	转子漏感/pu	0.16
定子电阻/pu	0.023	定转子互感/pu	2.9
定子漏感/pu	0.18	极对数	3
风速/m·s <sup>-1</sup>	10~15	SVPWM开关频率/kHz	1

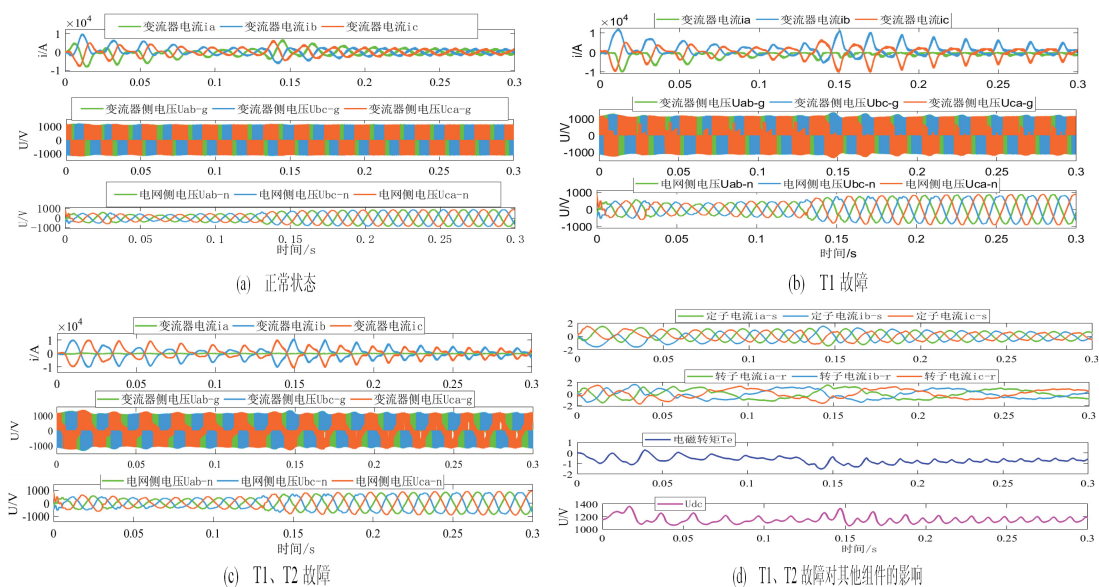


图 4 开路故障对发电系统的影响

当变流器正常运行时,变流器侧的电压、电流波形如图4(a)所示.当T1发生开路故障时,变流器相电流ia正半周期幅值丢失,并网电压Uab-g、Ubc-g、Uca-g出现失真,如图4(b)所示.

当同一桥臂上T1和T2同时故障时, 相电流 $i_b$ 和 $i_c$ 发生偏移, 相电流 $i_a=0$ , 且并网电压 $U_{ab-g}$ 、 $U_{bc-g}$ 、 $U_{ca-g}$ 亦失真, 严重影响电网安全, 如图4(c)所示. 如图4(d)所示, IGBT开路故障会导致双馈发电机电流发生畸变, 也会造成电磁转矩 $T_e$ 、直流端电压 $U_{dc}$ 的振荡发生畸变, 甚至会影响其他组件、降低电能质量、污染电网.

为了验证本文所提方法的有效性, 将数据集按照7:3的比例划分为训练集和测试集, 使用5种神经网络模型对IGBT模块进行故障诊断和对比分析. 5种神经网络迭代次数均为100, 其中SVM的惩罚系数为0.1, 线性核函数半径为0.000 3, 其余4种神经网络ELM网络结构相同. PSO的参数设置如下: 惯性权重为0.8, 自我学习因子和群体学习因子均为0.4, 粒子位置和速度区间分别为 $[-2,2]$ 、 $[-0.5,0.5]$ . GAWOA-ELM、WOA

-ELM、PSO-ELM算法中鲸鱼种群和粒子群规模大小均为50. 5种方法均运行30次, 准确率见表3. 由表3可知, 5种模型的平均诊断精度均在90%以上, 标准差分别为0.49%、0.34%、0.67%、0.43%、0.22%. SVM模型和ELM模型对IGBT模块故障诊断精度较低, PSO-ELM模型的标准差最高. GAWOA-ELM模型相比WOA-ELM模型, 可以自适应地改变算法在不同时期的寻优速度, 提高了算法搜索效率, GAWOA-ELM模型的平均诊断精度在98.99%至99.43%之间. 邻域扰动机制的引入提高了GAWOA-ELM模型的稳定性, 与其他4种神经网络模型相比, GAWOA-ELM模型标准差最小. 图5是GAWOA-ELM模型对IGBT模块故障诊断结果, 实验证明该模型能够满足变流器单IGBT模块和双IGBT模块故障模式下的故障诊断要求.

表 3 多种算法故障诊断精度

算法类型	算法准确度/%
SVM	90.76±0.49
ELM	91.14±0.34
PSO-ELM	96.53±0.67
WOA-ELM	98.53±0.43
<b>GAWOA-ELM</b>	<b>99.21±0.22</b>

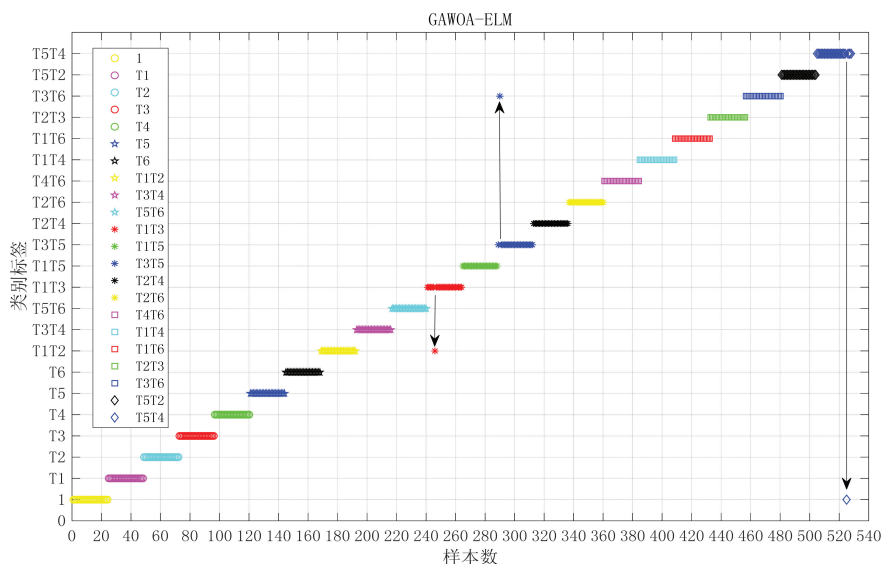


图 5 GAWOA-ELM模型对22种故障诊断结果

为了检测所提出的故障诊断方法的鲁棒性, 将不同的白噪声分别添加到原始故障电压信号中, 使用不同方法对不同信噪比下的故障电压信号进行诊断, 对数据集运行30次, 取算法的平均值, 结果见表4. 由表4可知, 当信噪比逐渐增大时, 不同模型的故障诊断精度整体都在降低, 且算法稳定性随之下降. 本文所提出的诊断方法在信噪比小于20 dB以下的变流器故障诊断中, 准确率均能保持在91.24%以上.

表 4 不同信噪比下各诊断算法准确率对比

算法类型	算法准确度/%			
	5 dB	10 dB	15 dB	20 dB
SVM	83.58±0.45	82.46±0.47	81.37±0.52	80.18±0.63
ELM	83.63±0.43	82.58±0.45	82.31±0.51	79.56±0.74
PSO-ELM	88.24±0.47	90.15±0.53	84.5±0.58	82.44±0.68
WOA-ELM	93.5±0.3	92.26±0.36	91.35±0.49	89.67±0.54
<b>GAWOA-ELM</b>	<b>96.35±0.23</b>	<b>94.5±0.27</b>	<b>92.81±0.36</b>	<b>91.72±0.48</b>

## 5 结论

本文以不同故障状态下网侧变流器三相线电压作为故障信号,为解决时域信号的周期性干扰,将时域信号转换成频域信号,利用三相线电压的谐波分量频率幅值和直流量幅值的差异,有效提取了不同故障类型的故障特征,提高了对变流器故障诊断的准确率。

GAWOA在WOA的基础上引入全局自适应权重,大大提高了WOA前期搜索速度和后期局部搜索精度,为ELM寻找到最优权值和阈值,同时引入邻域扰动机制,提高了算法的稳定性。最后通过与SVM、ELM、PSO-ELM、WOA-ELM对比,证明GAWOA-ELM的准确率和鲁棒性优于其他算法,在信噪比20 dB以下的变流器IGBT开路故障中,具有较高的准确率,结果表明GAWOA-ELM在风机变流器故障诊断方面具有很强的实用性。

## 参考文献:

- [1] 蔡国伟,雷宇航,葛维春,等.高寒地区风电机组雷电防护研究综述[J].电工技术学报,2019,34(22):4804-4815.
- [2] 张新燕,何山,张晓波,等.风力发电机组主要部件故障诊断研究[J].新疆大学学报(自然科学版),2009,26(2):140-144.
- [3] WATSON S, MORO A, REIS V, et al. Future emerging technologies in the wind power sector: a European perspective[J]. Renewable and Sustainable Energy Reviews, 2019, 113: 109270.
- [4] 孙晓云,高鑫,刘延华.柔性直流输电换流器故障特性分析及诊断研究[J].电力系统保护与控制,2017,45(2):75-84.
- [5] 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.
- [6] 刘星,姜睿智,宋国兵,等.利用电流故障特征的大功率整流装置故障在线诊断方法[J].电力系统保护与控制,2016,44(22):166-173.
- [7] LIANG J, ZHANG K, AI-DURRA A, et al. A novel fault diagnostic method in power converters for wind power generation system[J]. Applied Energy, 2020, 266: 114851.
- [8] CAMPOS-DELGADO D U, ESPINOZA-TREJO D R. An observer-based diagnosis scheme for single and simultaneous open-switch faults in induction motor drives[J]. IEEE Transactions on Industrial Electronics, 2010, 58(2): 671-679.
- [9] ZHAO H, CHENG L. Open-switch fault-diagnostic method for back-to-back converters of a doubly fed wind power generation system[J]. IEEE Transactions on Power Electronics, 2017, 33(4): 3452-3461.
- [10] ESTIMA J O, CARDOSO A J M. A new algorithm for real-time multiple open-circuit fault diagnosis in voltage-fed PWM motor drives by the reference current errors[J]. IEEE Transactions on Industrial Electronics, 2012, 60(8): 3496-3505.
- [11] ZHANG J, SUN H, SUN Z, et al. Fault diagnosis of wind turbine power converter considering wavelet transform, feature analysis, judgment and BP neural network[J]. IEEE Access, 2019, 7: 179799-179809.
- [12] ISMAIL A, SAIDI L, SAYADI M M. An open circuit switching fault diagnosis approach for back-to-back converter using wavelet analysis[C]. Sousse: 2019 10th International Renewable Energy Congress(IREC), IEEE, 2019: 1-6.
- [13] 施耀华,冯延晖,任铭,等.融合电流和振动信号的永磁同步风电系统变流器故障诊断方法研究[J].中国电机工程学报,2020,40(23):7750-7760.
- [14] 程静,王红琳.空间电压矢量脉宽调制在风电并网控制中的仿真研究[J].新疆大学学报(自然科学版),2013,30(1):110-114.
- [15] EKANAYAKE J B, HOLDSWORTH L, WU X G, et al. Dynamic modeling of doubly fed induction generator wind turbines[J]. IEEE Transactions on Power Systems, 2003, 18(2): 803-809.
- [16] 郭金东,赵栋利,林资旭,等.兆瓦级变速恒频风力发电机组控制系统[J].中国电机工程学报,2007,27(6):1-6.
- [17] YUAN Y, WANG Y, CAO F. Optimization approximation solution for regression problem based on extreme learning machine[J]. Neurocomputing, 2011, 74(16): 2475-2482.
- [18] LI K, XIONG M, LI F, et al. A novel fault diagnosis algorithm for rotating machinery based on a sparsity and neighborhood preserving deep extreme learning machine[J]. Neurocomputing, 2019, 350: 261-270.
- [19] NASIRI J, KHIYABANI F M. Whale optimization algorithm(WOA) approach for clustering[J]. Cogent Mathematics & Statistics, 2018, 5(1): 1483565.
- [20] 褚鼎立,陈红,王旭光.基于自适应权重和模拟退火的鲸鱼优化算法[J].电子学报,2019,47(5):992-999.