

## 基于 WPD-PSO 算法的整流电路故障诊断

王瀚<sup>1,2</sup>, 周海峰<sup>1,2</sup>, 郑东强<sup>3</sup>, 林忠华<sup>3</sup>, 张兴杰<sup>4</sup>, 关天敏<sup>5</sup>

- (1. 集美大学轮机工程学院, 福建 厦门 361021; 2. 福建省船舶与海洋工程重点实验室, 福建 厦门 361021;  
(3. 集美大学海洋装备与机械工程学院, 福建 厦门 361021; 4. 集美大学航海学院, 福建 厦门 361021;  
5. 集美大学海洋信息工程学院, 福建 厦门 361021)

**[摘要]** 针对电力电子电路故障类型多、诊断正确率低的问题, 提出基于小波包分解和粒子群算法优化概率神经网络的方法。建立三相桥式全控整流电路仿真模型, 利用小波包分解技术对故障电压信号进行三层小波包分解与重构, 提取特征值, 并对数据进行归一化处理; 用粒子群算法优化概率神经网络寻找合适的平滑因子, 对数据进行训练和诊断; 将方法与未优化的概率神经网络作对比。仿真结果表明, 该方法在训练效果和诊断正确率上都要优于未优化的概率神经网络。

**[关键词]** 电力电子电路; 故障诊断; 小波包分解; 粒子群算法; 平滑因子; 概率神经网络

**[中图分类号]** TN 711; TP 183

## Fault Diagnosis of Rectifier Circuit Based on WPD-PSO Algorithm

WANG Han<sup>1,2</sup>, ZHOU Haifeng<sup>1,2</sup>, ZHENG Dongqiang<sup>3</sup>, LIN Zhonghua<sup>3</sup>, ZHANG Xingjie<sup>4</sup>, GUAN Tianmin<sup>5</sup>

- (1. School of Marine Engineering, Jimei University, Xiamen 361021, China;  
2. Fujian Province Key Laboratory of Naval Architecture and Ocean Engineering, Xiamen 361021, China;  
3. School of Marine Equipment and Mechanical Engineering, Jimei University, Xiamen 361021, China;  
4. Navigation College, Jimei University, Xiamen 361021, China;  
5. School of Marine Information Engineering, Jimei University, Xiamen 361021, China)

**Abstract:** Aiming at the problem of multiple fault types and low diagnostic accuracy of power electronic circuits, a method of optimizing probabilistic neural network based on wavelet packet decomposition and particle swarm optimization was proposed. Firstly, the simulation model of three-phase bridge rectifier circuit was established, and the fault voltage signal was decomposed and reconstructed by three-layer wavelet packet decomposition technique, and the characteristic values were extracted and normalized. Then PSO was used to optimize the probabilistic neural network to find the appropriate smoothing factor, and the data was trained and diagnosed. Finally, compared with the unoptimized probabilistic neural network, the simulation results show that the method is superior to the unoptimized probabilistic neural network on both training effect and diagnosis accuracy.

**Keywords:** power electronic circuit; fault diagnosis; wavelet packet decomposition; particle swarm algorithm; smoothing factor; probabilistic neural network

**[收稿日期]** 2021-01-24

**[基金项目]** 国家自然科学基金项目(51179074); 福建省自然科学基金项目(2021J01839, 2018J01495); 集美大学安麦信产学研项目(S20127); 福建省教育厅项目(JAT200242, JAT170318)

**[作者简介]** 王瀚(1994—), 男, 硕士生, 从事电力电子故障诊断和直流变换器稳定性控制研究。通信作者: 周海峰(1970—), 男, 教授, 硕导, 从事智能信息处理和电力系统故障诊断研究。E-mail: zhfeng216@163.com

<http://xuebaobangong.jmu.edu.cn/zkb>

## 0 引言

在整流电路中,晶闸管作为整个电路的核心器件之一,如果出现了损坏,将严重影响电路的正常工作。为了确保电力电子设备正常稳定地工作,有必要考虑有效的故障诊断方法<sup>[1]</sup>。目前关于整流电路的故障诊断方法有许多,如:直接检测功率器件电压电流法、谱分析法(spectral analysis)和专家系统(expert system)等<sup>[2]</sup>;利用主成分分析提取故障特征<sup>[3-4]</sup>,在低维空间有着良好表现;基于小波分析和马氏距离的诊断方法在参数性故障及结构性故障中准确率更高<sup>[5]</sup>;采用分形神经网络的故障诊断的识别率都较高<sup>[6-7]</sup>;采用最小二乘支持向量机,可以实现整流电路的故障预测<sup>[8]</sup>;基于小波分析和随机森林算法的整流电路诊断方法,有着较高的正确诊断率和较强的抗噪声能力<sup>[9]</sup>。

本文以最常见的三相桥式全控整流电路作为故障诊断模型,提出了一种基于小波包分解(wavelet packet decomposition, WPD)和粒子群算法(particle swarm optimization, PSO)优化概率神经网络(probabilistic neural network, PNN)的整流电路故障诊断的方法。该方法首先对故障信号进行小波包的分解和重构,提取特征值;再通过设置 PSO 参数,对 PNN 进行优化,以便于找到合适的平滑因子  $\sigma$ ,将数据放入 PNN 中,完成故障分类。

## 1 小波包分解

### 1.1 小波包算法

小波包分解在时域和频域都具有很好的位置特征<sup>[10]</sup>,可以对信号进行时频分解,在不进行多分辨率分析的情况下,进一步分解高频部分,使  $\omega_n$  满足以下递推双尺度方程<sup>[11]</sup>:

$$\begin{cases} \omega_{2n}(t) = \sqrt{2 \sum_k h_n \omega_n(2t-k)}, \\ \omega_{2n+1}(t) = \sqrt{2 \sum_k g_n \omega_n(2t-k)}. \end{cases} \quad (1)$$

式中:  $t$ 、 $k$  为时间变量;  $h_n$  和  $g_n$  分别为比例系数和小波系数。

式(1)利用  $\omega_{2n}(t)$  和  $\omega_{2n+1}(t)$  将两个连续的空间滤波分解为相对低频和相对高频两个子带的精细分解方法具有较好的时频特性。子带的小波包系数可以分解为:

$$\begin{cases} d_1^{j,2n} = \sum_k \overline{h_{k-2l}} \times d_k^{j+1,n}, \\ d_1^{j,2n+1} = \sum_k \overline{g_{k-2l}} \times d_k^{j+1,n}. \end{cases} \quad (2)$$

其中:  $j$  为尺度因子;  $l$  为时间变量。

小波包重构算法为:  $d_k^{j+1,n} = \sum_k [h_{l-2k} d_k^{j,2n} + g_{l-2k} d_k^{j,2n+1}]$ 。小波包算法对被测信号进行三层分解,如图 1 所示。其中:  $S$  代表初始被测信号;  $A$  代表低频,  $B$  代表高频,末尾数字代表小波包分解层数。

### 1.2 特征能量提取

经过小波包分解后,所需频带能量的具体计算过程如下<sup>[12]</sup>。

如果每个频带  $S_j$  对应的能量为  $E_j$ , 则有:  $E_j = \int |S_j(t)|^2 dt = \sum_{k=1}^n |d_k^j|^2$ 。其中:  $d_k^j$  是重构信号的振幅;  $S_j$  是相应的离散信号点。

重构节点能量构成特征向量为:  $\mathbf{G} = [E_1, E_2, \dots, E_j]$ 。重构信号的总能量,则归一化向量可以表示为:  $\mathbf{G} = [E_1/E, E_2/E, \dots, E_j/E]$ 。

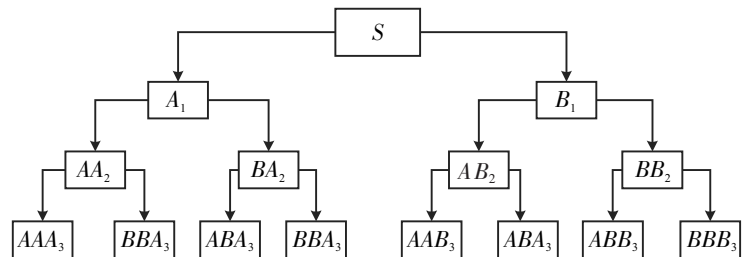


图 1 小波包分解结构

Fig.1 Wavelet packet decomposition structure

## 2 PNN 和 PSO 概述

### 2.1 PNN 结构

PNN 的基本结构如图 2 所示。与 BP 神经网络相比, PNN 具有收敛快, 稳定性高的特点, 因此, PNN 比 BP 神经网络更适合电力电子电路故障诊断<sup>[13-15]</sup>。

基于 PNN 的故障诊断可以描述为: 已知故障模式为  $A$ 、 $B$ , 故障特征样本  $X = (x_1, x_2, \dots, x_n)$ 。若  $m_A n_A f_A(X) > m_B n_B f_B(X)$ , 则  $X \in A$ ; 若  $m_A n_A f_A(X) < m_B n_B f_B(X)$ , 则  $X \in B$ 。式中:  $m_A$

、 $m_B$  分别为故障模式  $A$ 、 $B$  的先验概率;  $n_A$ 、 $n_B$  分别为代价因子;  $f_A$ 、 $f_B$  为  $A$ 、 $B$  的概率密度函数, 可以近似的用  $f_A(X) = [1/((2\pi)^{p/2}\delta^p)](1/q) \sum \exp[-(X - X_{Ai})^T(X - X_{Ai})/(2\delta^2)]$  表示。式中:  $X_{Ai}$  为故障模式  $A$  的第  $i$  个训练向量;  $q$  为故障模式  $A$  的训练样本数目;  $\delta$  为平滑因子, 其取值将会影响最终的诊断效果。

### 2.2 粒子群算法

粒子群优化算法是一种群体智能算法<sup>[16]</sup>, 具体步骤如下。

步骤 1 随机初始化种群中每个粒子的位置  $X_i$  和速度  $V_i$ ;

步骤 2 计算每个粒子的个体适应度值、个体最优值, 以及整个群体的全局最优值;

步骤 3 更新当前粒子的速度和位置,  $V_{ij}(t+1) = V_{ij}(t) + c_1 r_1(t)[p_{ij}(t) - x_{ij}(t)] + c_2 r_2(t)[p_{gj}(t) - x_{ij}(t)]$ ;  $X_{ij}(t+1) = X_{ij}(t) + V_{ij}(t+1)$ 。其中:  $c_1$  和  $c_2$  为学习因子;  $r_1$  和  $r_2$  是属于  $[0, 1]$  之间的随机数。

步骤 4 进行边界条件处理。

步骤 5 判断是否满足终止条件, 若是, 则输出优化结果; 否则返回步骤 2。

### 2.3 PSO 优化 PNN

平滑因子  $\delta$  影响 PNN 的分类, 根据经验选择平滑因子不能反映整个样本空间的概率特征, 分类精度较低。粒子群优化算法可以在不需要任何先验知识的情况下发现系统内部的潜在关系, 因此, 在故障诊断方面有着广泛的应用。经过 PSO 优化的 PNN 模型, 可以对训练数据集进行训练并选出最佳参数, 从而提高了 PNN 的泛化性能, 优化流程如图 3 所示。




图 2 PNN 结构  
Fig.2 Structure of PNN

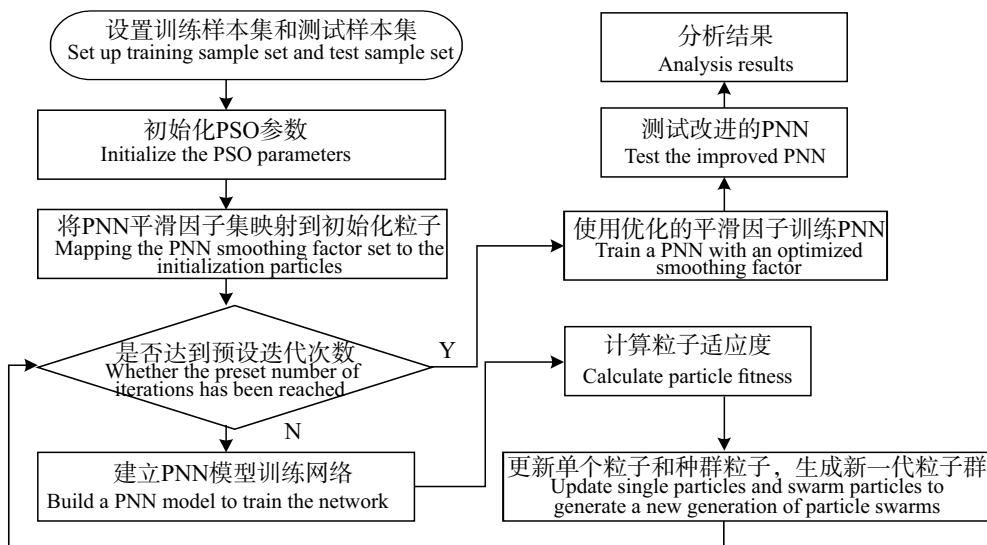


图 3 PSO-PNN 平滑因子优化流程图

Fig.3 Optimization flowchart of PSO-PNN smooth factor

粒子群优化需要初始化参数，其中学习因子  $c_1$  和  $c_2$  设为 1.5，最大迭代次数为 100，种群数为 10，5 倍交叉验证（5 - CV）。平滑因子的最大值为 30，最小值为 0.1，PSO 的适应度函数<sup>[17]</sup> 为：

$E_p = \sum_1^p E_p = \sum_1^p \|d(X_j) - y(X_j)\|$ 。式中： $d(X_j)$  为期望输出； $y(X_j)$  为实际输出。

### 3 基于 WPD-PSO 优化 PNN 的故障诊断

#### 3.1 故障分类

三相全控整流电路如图 4 所示，其中电阻  $R$  为纯电阻负载。晶闸管开路分为一只晶闸管开路、两只晶闸管开路和三只晶闸管开路（不常见所以不予考虑）<sup>[18]</sup>。本文将正常运行状态也并入故障之一，故障类型见表 1。




图 4 三相全控整流电路图

Fig.4 Circuit diagram of three-phase fully controlled rectifier

表 1 故障类型

Tab. 1 Fault types

| 故障分类<br>Fault classification | 大类<br>Main type  | 小类<br>Small type  |
|------------------------------|--|---|
| 1                            | 正常 Normal  | 无 No  |
| 2                            | 一只晶闸管开路 A thyristor is open  | 1. VT <sub>1</sub> , 2. VT <sub>2</sub> , 3. VT <sub>3</sub> , 4. VT <sub>4</sub> , 5. VT <sub>5</sub> , 6. VT <sub>6</sub>   |
| 3                            | 同一半桥两只晶闸管开路 Two thyristors in the same half-bridge open circuit  | 1. VT <sub>1</sub> , VT <sub>4</sub> , 2. VT <sub>3</sub> , VT <sub>6</sub> , 3. VT <sub>2</sub> , VT <sub>5</sub>  |
| 4                            | 同一极性两只晶闸管开路 Two thyristors of the same polarity are open   | 1. VT <sub>1</sub> , VT <sub>3</sub> , 2. VT <sub>1</sub> , VT <sub>5</sub> , 3. VT <sub>3</sub> , VT <sub>5</sub> , 4. VT <sub>2</sub> , VT <sub>4</sub> , 5. VT <sub>2</sub> , VT <sub>6</sub> , 6. VT <sub>4</sub> , VT <sub>6</sub> |
| 5                            | 不同极性两只晶闸管开路 (除第二大类) Two thyristors of different polarities are open circuit (except the second category) | 1. VT <sub>1</sub> , VT <sub>6</sub> , 2. VT <sub>1</sub> , VT <sub>2</sub> , 3. VT <sub>2</sub> , VT <sub>3</sub> , 4. VT <sub>3</sub> , VT <sub>4</sub> , 5. VT <sub>4</sub> , VT <sub>5</sub> , 6. VT <sub>5</sub> , VT <sub>6</sub> |

#### 3.2 建立电路模型和能量特征提取

利用 MATLAB 2017b Simulink 9.0 仿真工具箱搭建仿真模型，选用  $u_d$  作为分析故障信号，这是因为：1) 电压容易测量；2) 当电路发生不同的故障时， $u_d$  的波形会因此而改变，可以通过观察电压波形来判断故障类型。

为了保证仿真实验有足够的样本数据，分别选取了触发角为 0°、5°、10°、15°、20°、25°、30°、35°、40°、45°、50°、55°、60°、65°、70°、75°、80°、85°和 90°时的故障电压信号作为样本，仿真时间为 0.08 s，采样时间为 0.0004 s，频率为 50 Hz，采样点数 201 个，选取其中 50 个点组成故障信号。图 5 为触发角为 0°时的部分故障电压波形，对三相桥式整流电路故障电压  $u_d$  的信号波形进行 3 层小波包分解与重构，提取相应的信号特征，得到特征能量值。

三相全控整流电路一共有 22 种故障，触发角共 19 组，所以样本总集数为 418。在 MATLAB 程序中将得到的数据打乱顺序，随机选择样本总集中的 369 个样本作为训练集，49 个样本作为测试集。采集的数据可能会出现很大的差异，最终可能会导致分类效果变得很差。为了得到更好的分类效果和更准确的分类精度，将故障数据全部整合到 [0,1] 区间段，将数据归一化。部分归一化数据见表 2。




图5 故障电压波形

Fig.5 Fault voltage waveform

表2 部分故障数据

Tab.2 Partial failure data

| 编号<br>Number | 大类<br>Main type | 小类<br>Small type | 故障管<br>Fault tube                 | 输入 Input |       |       |       |       |       |       |       |
|--------------|-----------------|------------------|-----------------------------------|----------|-------|-------|-------|-------|-------|-------|-------|
|              |                 |                  |                                   | $E_0$    | $E_1$ | $E_2$ | $E_3$ | $E_4$ | $E_5$ | $E_6$ | $E_7$ |
| 1            | 1               | 1                | 无                                 | 1.000    | 0.521 | 0.299 | 0.395 | 0.186 | 0.159 | 0.097 | 0.042 |
| 2            | 2               | 1                | VT <sub>1</sub>                   | 0.985    | 0.458 | 0.289 | 0.974 | 0.197 | 0.155 | 0.083 | 0.048 |
| 3            | 2               | 2                | VT <sub>2</sub>                   | 1.000    | 0.429 | 0.310 | 0.410 | 0.168 | 0.148 | 0.091 | 0.044 |
| 4            | 2               | 3                | VT <sub>3</sub>                   | 0.851    | 0.465 | 0.322 | 0.382 | 0.194 | 0.142 | 0.084 | 0.037 |
| 5            | 2               | 4                | VT <sub>4</sub>                   | 0.794    | 0.385 | 0.276 | 0.376 | 0.230 | 0.139 | 0.095 | 0.299 |
| 6            | 2               | 5                | VT <sub>5</sub>                   | 0.982    | 0.364 | 0.341 | 0.355 | 0.179 | 0.147 | 0.087 | 0.039 |
| 7            | 2               | 6                | VT <sub>6</sub>                   | 1.000    | 0.489 | 0.298 | 0.367 | 0.215 | 0.199 | 0.071 | 0.035 |
| 8            | 3               | 1                | VT <sub>1</sub> , VT <sub>4</sub> | 0.862    | 0.425 | 0.198 | 0.301 | 0.174 | 0.142 | 0.069 | 0.031 |
| 9            | 3               | 2                | VT <sub>3</sub> , VT <sub>6</sub> | 0.796    | 0.398 | 0.200 | 0.298 | 0.162 | 0.133 | 0.078 | 0.028 |
| 10           | 3               | 3                | VT <sub>2</sub> , VT <sub>5</sub> | 1.000    | 0.486 | 0.187 | 0.267 | 0.166 | 0.144 | 0.086 | 0.024 |
| 11           | 4               | 1                | VT <sub>1</sub> , VT <sub>3</sub> | 0.752    | 0.367 | 0.147 | 0.276 | 0.144 | 0.000 | 0.058 | 0.009 |
| 12           | 4               | 2                | VT <sub>1</sub> , VT <sub>5</sub> | 0.811    | 0.331 | 0.152 | 0.196 | 0.148 | 0.087 | 0.060 | 0.012 |
| 13           | 4               | 3                | VT <sub>3</sub> , VT <sub>5</sub> | 0.586    | 0.372 | 0.153 | 0.185 | 0.135 | 0.079 | 0.054 | 0.004 |
| 14           | 4               | 4                | VT <sub>2</sub> , VT <sub>4</sub> | 0.572    | 0.330 | 0.145 | 0.000 | 0.142 | 0.069 | 0.051 | 0.018 |
| 15           | 4               | 5                | VT <sub>2</sub> , VT <sub>6</sub> | 0.683    | 0.427 | 0.149 | 0.203 | 0.146 | 0.058 | 0.049 | 0.000 |
| 16           | 4               | 6                | VT <sub>4</sub> , VT <sub>6</sub> | 0.643    | 0.298 | 0.197 | 0.243 | 0.150 | 0.105 | 0.048 | 0.007 |
| 17           | 5               | 1                | VT <sub>1</sub> , VT <sub>6</sub> | 0.823    | 0.384 | 0.157 | 0.243 | 0.155 | 0.098 | 0.078 | 0.019 |
| 18           | 5               | 2                | VT <sub>1</sub> , VT <sub>2</sub> | 0.813    | 0.379 | 0.162 | 0.271 | 0.162 | 0.100 | 0.071 | 0.016 |
| 19           | 5               | 3                | VT <sub>2</sub> , VT <sub>3</sub> | 0.784    | 0.481 | 0.187 | 0.251 | 0.149 | 0.086 | 0.067 | 0.023 |
| 20           | 5               | 4                | VT <sub>3</sub> , VT <sub>4</sub> | 0.757    | 0.386 | 0.000 | 0.326 | 0.157 | 0.091 | 0.062 | 0.021 |
| 21           | 5               | 5                | VT <sub>4</sub> , VT <sub>5</sub> | 0.783    | 0.314 | 0.172 | 0.204 | 0.147 | 0.134 | 0.059 | 0.018 |
| 22           | 5               | 6                | VT <sub>5</sub> , VT <sub>6</sub> | 0.765    | 0.385 | 0.176 | 0.200 | 0.153 | 0.197 | 0.062 | 0.020 |

## 4 仿真结果分析

将归一化后的数据放入经 PSO 优化后的网络中进行训练, 输入量是故障数据, 输出量是分类结果。图 6 为训练误差图, 可以清晰地看到哪些样本被错误训练, 红色 ‘\*’ 与蓝色 ‘o’ 重合表示训

练正确。从图 6 中可以看出, 在 369 个训练样本总集中存在 3 个样本被错误训练, 训练正确率为 98.37%。PSO-PNN 分类效果如图 7 所示, 在 49 个测试样本中, 只有 1 个样本被错误诊断, 其他全部正确, 故障诊断正确率为 97.96%。

为了进一步分析 WPD-PSO-PNN 模型的识别性能, 本文采用了未优化的概率神经网络 (经验情况下, 平滑因子  $\sigma$  为 1.5) 对同一故障训练集和测试集进行故障识别。未优化的 PNN 网络训练误差和分类效果如图 8 ~ 图 9 所示。从图 8 中可以看出有 356 个样本被正确训练, 13 个样本被错误训练, 训练正确率为 96.48%。图 9 可以看出有 45 个样本诊断正确, 4 个样本诊断错误, 诊断识别率为 91.84%。两种诊断方法的训练效果和分类效果如表 3 所示。




图 6 PSO-PNN 训练误差

Fig.6 PSO-PNN training error




图 7 PSO-PNN 分类效果

Fig.7 PSO-PNN classification effect




图 8 PNN 训练误差

Fig.8 PNN training error




图 9 PNN 分类效果

Fig.9 PNN classification effect

表 3 两种诊断方法的效果

Tab.3 Effects of two diagnostic methods

| 诊断方法<br>Diagnostic methods | 正确训练<br>The correct training |                               | 错误训练<br>Thewrong training |                               | 总集<br>Total set          |                        | 效率<br>Efficiency/%             |                                      |
|----------------------------|------------------------------|-------------------------------|---------------------------|-------------------------------|--------------------------|------------------------|--------------------------------|--------------------------------------|
|                            | 训练效果<br>Training effect      | 分类效果<br>Classification effect | 训练效果<br>Training effect   | 分类效果<br>Classification effect | 训练总集<br>The training set | 样本总集<br>The sample set | 训练正确率<br>The training accuracy | 诊断识别率<br>Diagnostic recognition rate |
| WPD-PSO-PNN                | 363                          | 48                            | 3                         | 1                             | 369                      | 49                     | 98.37                          | 97.96                                |
| PNN                        | 356                          | 45                            | 13                        | 4                             | 369                      | 49                     | 96.48                          | 91.84                                |



## 5 结论

本文采用 WPD-PSO 算法优化 PNN 的方法对三相全控整流电路进行故障诊断, 解决了整流电路故障类型多、诊断过程繁杂和诊断正确率低的问题。仿真结果表明, 该方法在训练效果和故障识别率方面都要优于未优化的概率训练结构方法, 说明该方法对整流电路的故障诊断具有更高的诊断识别率, 同时可以为其他电路的故障诊断提供重要的借鉴意义和参考价值。

## [ 参 考 文 献 ]

- [1] RONGJIE W, YIJU Z, MEIQIAN C, et al. Application of similarity in fault diagnosis of power electronics circuits [J]. IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, 2010, 93(6): 1190-1195.
- [2] RONGJIE W, YIJU Z, MEIQIAN C, et al. Fault diagnosis technology based on wigner - ville distribution in power electronics circuit [J]. International Journal of Electronics, 2011, 98(9): 1247-1257.
- [3] 周海峰, 王荣杰, 崔博文. 一种用于三相整流装置故障诊断的方法 [J]. 太阳能学报, 2013, 34(1): 171-176.
- [4] 陈宏, 邓芳明, 吴翔, 等. 基于梯度提升决策树的电力电子电路故障诊断 [J]. 测控技术, 2017, 36(5): 9-12, 20.
- [5] 盛艳燕, 胡志忠. 基于小波和马氏距离的电力电子电路故障诊断 [J]. 电子测量技术, 2013, 36(2): 108-112.
- [6] 张米露, 王天真, 汤天浩. 一种融合分形与 BP 网络 PCA 的海流机故障检测方法 [J]. 电机与控制学报, 2018, 22(2): 79-88.
- [7] 王立平, 陈仁文. 基于小波包分形的电力电子故障诊断方法 [J]. 测控技术, 2017, 36(5): 5-8.
- [8] 宋强, 翟雁. 基于最小二乘支持向量机的电力电子电路故障诊断应用研究 [J]. 数学的实践与认识, 2016, 46(1): 125-130.
- [9] 蔡金锭, 鄢仁武. 基于小波分析与随机森林算法的电力电子电路故障诊断 [J]. 电力科学与技术学报, 2011, 26(2): 54-60.
- [10] HU Q, QIN A, ZHANG Q, et al. Fault diagnosis based on weighted extreme learning machine with wavelet packet decomposition and KPCA [J]. IEEE Sensors Journal, 2018(99): 1-1.
- [11] TANG J, LIU Q, HU J, et al. Leakage fault diagnosis method of aircraft landing gear hydraulic cylinder based on wavelet packet [J]. The Journal of Engineering, 2019(13): 427-431.
- [12] WANG W, YAN L, JIN T, et al. Inrush current method of transformer based on wavelet packet and neural network [J]. The Journal of Engineering, 2019(16): 1257-1260.
- [13] 于生宝, 何建龙, 王睿家, 等. 基于小波包分析和概率神经网络的电磁法三电平变换器故障诊断方法 [J]. 电工技术学报, 2016, 31(17): 102-112.
- [14] 王熙乾, 高雪莲, 史丽鹏. 基于 WOA-PNN 算法的电力电子电路故障诊断分析 [J]. 微电子学, 2020, 50(2): 232-235.
- [15] 马天兵, 王鑫泉, 王孝东. 基于 EMD-PNN 网络的刚性罐道故障诊断方法 [J]. 电子测量与仪器学报, 2019(3): 58-64.
- [16] 黄少荣. 粒子群优化算法综述 [J]. 计算机工程与设计, 2009, 30(8): 1977-1980.
- [17] 陈波, 郭壮志. 基于优化平滑因子  $\sigma$  的概率神经网络的变压器故障诊断方法研究 [J]. 现代电力, 2007, 24(2): 44-47.
- [18] 姜艳姝, 吴迪, 王伟亮. 基于 BP 神经网络的整流电路的故障诊断 [J]. 哈尔滨理工大学学报, 2018, 23(2): 35-39.

(责任编辑 陈 敏 英文审校 郑青榕)