

DOI: 10.13382/j.jemi.B2205661

基于 GA-BRBPNN 的航空自耦变压整流器 故障诊断方法*

董慧芬 郑坤 杨占刚

(中国民航大学电子信息与自动化学院 天津 300300)

摘要:航空自耦变压整流器(auto-transformer rectifier unit, ATRU)是飞机高压直流电网关键电能变换装置,在运行过程中受高温、机械应力、荷载波动等因素持续影响,其内部元件可能出现相应故障,进而威胁飞机可靠运行及持续适航。针对 ATRU 整流部分故障信号频谱难以区分、诊断准确率不高问题,提出一种遗传算法(genetic algorithm, GA)与贝叶斯正则化反向传播神经网络(Bayesian regularisation back propagation neural network, BRBPNN)相结合的故障诊断识别方法。首先,实现 ATRU 故障仿真,以时频分析方式处理所得信号,从而挖掘不同故障状态的特征信息;随后采用 GA 算法优化 BRBPNN 初始权阈值并建立最优 GA-BRBPNN 诊断模型,将特征样本输入诊断模型进行故障分类识别,测试模型性能;最后,搭建故障模拟实验平台对实测数据进行模型验证。实验结果分析可知,对于仿真故障,该模型诊断准确率可达 99.46%,对于实测故障,该模型可全部诊断识别待测样本;由此表明提出的 GA-BRBPNN 优化模型诊断效果好,具有较高实用价值。

关键词:航空自耦变压整流器;BP 神经网络;遗传算法;贝叶斯正则化;故障诊断

中图分类号: TM461; TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault diagnosis method for auto-transformer rectifier unit based on GA-BRBPNN

Dong Huifen Zheng Kun Yang Zhangang

(College of Electronics Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aeronautical auto-transformer rectifier unit (ATRU) is the key power conversion device of aircraft high-voltage DC power grid. It is continuously affected by high temperature, mechanical stress, load fluctuation and other factors during operation, then its internal components may appear corresponding failure, which can lead to threaten the reliable operation and continued airworthiness of the aircraft. The spectrum of the fault signal in the rectifier part of ATRU is difficult to distinguish and the diagnostic accuracy is low, a fault diagnosis method based on genetic algorithm (GA) combined with Bayesian regularization back propagation neural network (BRBPNN) is proposed. Firstly, an ATRU fault simulation model is implemented and then the collected signals are processed by means of time-frequency analysis so as to mine the feature information of different fault states. Subsequently, genetic algorithm is used to optimize the initial weights and thresholds of BRBPNN and the optimal GA-BRBPNN diagnosis model is established. The feature samples are introduced into the diagnosis model for fault identification and model performance testing. Finally, the experiment platform of fault simulation is built and the measured fault data is used to validate the method. The experimental results show that the diagnostic accuracy of the proposed method can reach 99.46% for the simulated faults and the method can diagnose and identify all the samples to be tested for the actual faults. Therefore, the method based on GA-BRBPNN has good diagnostic effect and high practical value.

Keywords: aeronautical autotransformer rectifier unit; BP neural network; genetic algorithm; Bayesian regularization; fault diagnosis

0 引言

在 B787 飞机电网中, ATRU 将交流母线 235 V 宽频交流电整流为 270 V 高压直流电, 供液压电动泵、冲压风机电机以及环控压缩机等 12 个大功率负载装置使用。飞机高压直流电力系统工况复杂多变, ATRU 内部器件长期受到诸如温度、机械应力和大功率负载频繁启停带来的巨大冲击等因素影响, 难免出现故障。目前国内外学者对 ATRU 的研究大多集中在优化整体结构和改善输入输出性能^[1-3]等方面, 但在其故障监测和诊断方面研究甚少; 而 ATRU 作为航空领域重要的大功率电力电子变换装置, 其核心构成部件—变压器和大功率整流器一直是故障诊断领域关注的重点。

变压器常见故障为绕组开路和绝缘老化脱落导致的匝间短路; 整流桥故障包括二极管短路和开路。通常在大功率整流情况下, 二极管短路故障发生迅速, 并会由于电流瞬时过大而迫使器件损坏, 故短路故障最终表现是开路形态, 并且很少有 3 个及以上的二极管同时发生故障^[4]。主流故障诊断方法分为解析模型法、信号处理法及人工智能法。解析模型法依赖于所建数学模型精确程度且针对性极强, 推广困难。信号处理法多从故障信号入手进行分析, 如文献[5]采用输入输出电能信号波形特征进行大功率整流器二极管开路故障诊断, 该法虽不受故障位置、故障时间及运行荷载等因素影响, 但分析对比步骤繁多; 傅里叶变换法^[6]一直被认为是快速分辨信号异常的手段, 但该法极易丢失时域或局部重要信息, 而小波分析法^[7-9]恰可以克服这些不足, 所以电气设备故障诊断中常用小波分析, 如文献[9]采集高压断路器合闸、分闸故障运行的振动信号, 利用小波变换进行分析处理, 提取出突变起始时刻特征, 实现异常状态辨识, 但该方法需要大量量化、对比分析。人工智能法常与信号处理法结合进行故障诊断, 主要包括专家系统法、支持向量机法和神经网络法等。工程应用中, 专家系统法建立知识库不易; 支持向量机模型本质为二分类, 面对多类故障时其所需建立的分类模型也会增加; 神经网络法中 BP 神经网络泛用性强, 具有良好的非线性计算能力和强大的学习能力, 但其极易陷入局部最优且在小样本训练下性能较差, 对此文献[10]先将变压器故障数据聚类分析, 再利用列文伯格-马夸尔特(Levenberg-Marquardt, LM)算法改进的 BP 神经网络进行诊断, 但其中多类故障识别准确率仍旧不高; 文献[11]采用堆叠多个残差子网络来加深 BP 神经网络深度, 从而提高模型性能, 但深层网络训练不易; 文献[12]和[13]分别选用差分进化算法和改进蝴蝶优化算法优化 BP 神经网络权阈值从而对变压器故障进行诊断, 虽取得不错效果, 但均未考虑小样本情况下神

经网络训练次数过多导致的过度学习^[14]问题。

为解决上述问题, 本文提出了基于 GA-BRBPNN 的故障诊断方法, 对相近故障信号进行多维时频特征提取, 提升算法整体诊断效率和分辨能力; 采用遗传算法对 BP 神经网络初始权阈值进行优化搜索, 防止模型陷入局部极值点; 采用贝叶斯正则化方法来减弱甚至消除因 BP 神经网络过度训练所带来的负面影响。实验结果表明, 该法在仿真和实测数据下故障诊断性能均优于其他方法, 为 ATRU 故障诊断提供一种新思路。

1 GA-BRBPNN 故障诊断算法

GA-BRBPNN 故障诊断算法将 BP 神经网络、遗传算法及贝叶斯正则化方法三者有机结合在一起, 遗传算法中选择、交叉和变异操作能高效辅助 BP 神经网络分类器脱离局部极值点, 而贝叶斯正则化方法又能及时避免网络中某些权重影响过大, 防止模型拟合过度。算法输入为故障时频特征, 输出为故障类别编码, 原理框图如图 1 所示。




图 1 GA-BRBPNN 故障诊断算法框图

Fig. 1 GA-BRBPNN fault diagnosis algorithm schematic diagram

1.1 BP 神经网络

在故障诊断方法中, BP 神经网络结构简单, 应用广泛且效果显著, 故成为首选算法。其整体训练过程主要包括相关数据正向传递及训练误差反馈校正两个部分。典型 BP 神经网络包含输入输出层和一个隐层, 相同层神经元节点并无信息交互, 异层神经元节点形成网状连接。神经元拓扑结构如图 2 所示, 图中 $x_i (i=1, 2, 3, \dots, n)$ 为输入, $W_i (i=1, 2, 3, \dots, n)$ 为连接权重, b_x 为偏置项, Σ 为求和操作, θ 为阈值, f 为激活函数, y 为输出。

神经网络的权值和阈值是两个极为重要的参数。数据在前后层之间传送需要通过带权值的连接, 而神经元节点产生输出的必要条件是其所接收到的信息和达到激活阈值。权值 W 与阈值 θ 的初值设定影响神经网络的训练效果和泛化评测, 容易导致 BP 神经网络分类器因陷入局部极值而对故障状态造成误判。与粒子群、模拟退火等算法相比, 遗传算法^[15-16]更宜处理高维复杂问题, 其




图2 神经元拓扑结构

Fig. 2 Neuron topology structure

寻优机制具有更强的随机性,易得到可信的全局最优解,故选用遗传算法对初始权阈值进行优化。

1.2 遗传算法

遗传算法的优化思想源自 Darwin 的进化论和 Montesquieu 的遗传学说,其目的是实现求解空间中最优解的自适应搜索。在对初始权值 W 和初始阈值 θ 的最优搜索中,遗传算法主要步骤包括编码策略、初始种群设定、适应度函数制定、选择-交叉-变异算子设计、运行参数设置 5 个部分。此处遗传算法采用实值编码、轮盘赌选择、模拟二进制交叉和多项式变异方式,变量范围设置为 $[-5, 5]$,利用训练样本的网络训练误差构造适应度函数 Q ,其设定如式(1)所示。

$$Q = \frac{1}{M^2} \sum_{i=1}^J [y_i - r_i]^2 \quad (1)$$

式中: M 为种群数量, J 为输出层神经元节点个数, y 为当前进化代次下的神经网络训练预测输出值, r 为故障实际类别编码值。

BP 神经网络结合遗传算法进行初始权阈值优化时,整体模型长时间迭代训练极易造成过度拟合。而在防止过拟合措施中,贝叶斯正则化方法^[17]拥有更严密的理论论证,以贝叶斯最大后验估计方式得到的神经网络优化模型更加可靠,故采用贝叶斯正则化方法对 BP 神经网络的综合泛化能力进行改善提升。

1.3 贝叶斯正则化方法

贝叶斯正则化方法主要在 BP 神经网络损失函数中添加与网络权重相关的惩罚项,目的是缩减求解空间,从而减小求得过度拟合解的概率。建立目标函数 G 如式(2)所示。

$$\begin{cases} E_d = \frac{1}{N} \sum_{n=1}^N (y - r)^2 \\ e_w = \frac{1}{N_w} \sum_{i=1}^{N_w} W_i^2 \\ G = \varphi E_d + \eta e_w \end{cases} \quad (2)$$

式中: E_d 为神经网络常用损失函数,此处以输出响应的均方差为例, N 为所选训练集样本总数, y 为预测值, r 为实际值; e_w 为网络权重平方和均值,即为惩罚项, N_w 为权重个数, W_i 为第 i 个权重; φ, η 为惩罚因子。由贝叶斯理

论,对应目标函数 G 取最小值时,关键参数计算如式(3)所示:

$$\begin{cases} \varphi = \frac{N_w - \gamma}{2E_d} \\ \eta = \frac{\gamma}{2e_w} \\ \gamma = N_w - 2\eta \cdot \text{tr}(\mathbf{H})^{-1} \end{cases} \quad (3)$$

式中: γ 为有效权重个数, \mathbf{H} 为损失函数海森矩阵。BP 神经网络训练时,贝叶斯正则化算法可自适应地对 φ 和 η 进行调整,若 $\varphi \gg \eta$,则目标函数 G 中 E_d 项作用更大,算法会最大程度的增加训练精度;若 $\varphi \ll \eta$,算法则会通过惩罚项使得网络的有效权重尽可能地少且小,从而精简模型,防止过度拟合。

通过 GA 算法选择、交叉和变异操作,种群中优秀个体得以选中、优良模式得以遗传,从而找出 BP 神经网络初始权阈值最优解,算法整体实现流程如图 3 所示。

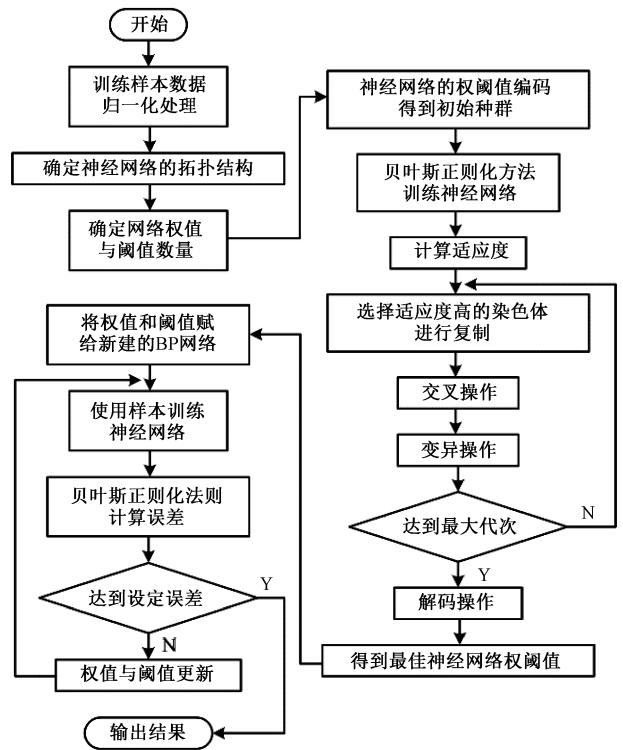


图3 GA-BRBPNN 算法流程

Fig. 3 Flow chart of GA-BRBPNN

2 ATRU 故障仿真与诊断分析

2.1 ATRU 建模与故障分析

大功率整流场合常用多脉波整流方式^[1-2]来抑制谐波。多脉波整流一般先用变压器将三相电进行移相,后经多组整流桥输出多相电流互相叠加来抵消谐波。而自

耦变压整流器的移相变压器为自耦型,具有重量轻、体积小及传输效率高等优点,被广泛应用于航空电源。本文研究对象为新型 18 脉波 ATRU,电气原理如图 4 所示。其整流部分由主桥和两个辅桥并联构成,共有 18 个整流二极管,为方便后续说明,按顺序编号 $D_1 \sim D_{18}$ 。额定输入 115 V/400 Hz、带载 3 kW 时,ATRU 仿真输出直流电压为 280 V,输入电流总谐波畸变率 3.56%,输出电流总谐波畸变率 9.77%,均满足 GJB 181B-2012 对航空器高压直流供电特性的要求,仿真参数设置如表 1 所示。

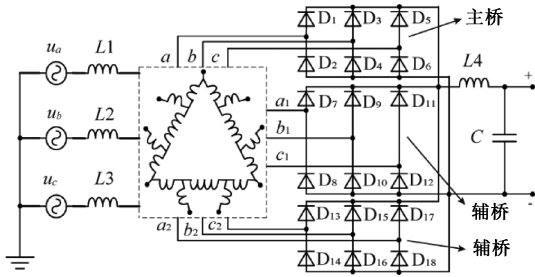


图 4 ATRU 电气原理图

Fig. 4 ATRU electrical schematic

表 1 仿真参数

Table 1 Simulation parameters

参数	名称	数值设置
u_a	输入电压/V	115
f_u	输入频率/Hz	400
$L1$	输入滤波电感/ μ H	60
$L4$	输出滤波电感/mH	1
C	输出滤波电容/nF	500

ATRU 故障仿真中,自耦变压器故障包含匝间短路 1 匝和绕组开路故障,整流桥故障包含单二极管开路和双二极管开路故障。由于二极管数量较多,故障组合种类繁多,此处仅选取同类故障中的典例进行探讨。结合实际仿真模型,采用额定输入、空载时 ATRU 输出直流电压信号构建原始波形数据样本,采样频率为 1 MHz,仿真时间为 0.01 s,每组波形 10 000 点数据。

采用快速傅里叶变换方法对信号进行频域分析可得,信号频谱难以区分的故障模式集中在整流桥故障,如表 2 所示 8 种故障,主要表现为整流桥同相整流上、下桥臂开路故障信号波形、频谱极为相似,故障定位相对困难。其中 D_1 开路故障与 D_2 开路故障波形、频谱对比如图 5 所示。故此类整流桥故障识别与定位,需要依靠多维时频特征提取的方式在故障波形数据中全面挖掘故障特征。


2.2 多维时频特征提取与特征集构建

故障信号时域特征^[18]往往能携带相关故障模式重要信息。考虑到单纯时域分析的局限性,引入时频分析

表 2 频谱难以区分故障类型


Table 2 Spectrum indistinguishable fault types table

编号	故障名称	故障位置
1	主桥上半桥臂开路	D_1
2	主桥下半桥臂开路	D_2
3	辅桥上半桥臂开路	D_7
4	辅桥下半桥臂开路	D_8
5	主桥上半桥双二极管开路	D_1, D_3
6	主桥下半桥双二极管开路	D_2, D_4
7	同辅桥上半桥双二极管开路	D_7, D_9
8	同辅桥下半桥双二极管开路	D_8, D_{10}



(a) 遗传进化曲线

(a) The curve of genetic evolution



(b) 测试集误差分布

(b) Error distribution of the test sets

图 5 主桥上下桥臂开路波形及频谱对比

Fig. 5 Comparison of open circuit waveforms and spectras of the upper and lower bridge arms of the main bridge

方法中更具有优势的小波包分解^[19-21] (wavelet packet decomposition, WPD) 来对故障信号进行特征提取。小波包分解可将信号子频带按一定尺度再分为低频及高频部分,时频分辨率更高,信号局部特征可得以大幅保留。不同故障模式下 ATRU 输出电能信号包含的能量信息极为丰富,分解所得小波包能量系数可作为故障信号重要时频特征。选取可减少信号失真度的 Sym4 小波对故障信号进行 3 次小波包分解,并提取底层 8 个子频带能量系数 $WPD_E_i (i=1, 2, \dots, 8)$, 全部时频特征如表 3 所示。

ATRU 输入三相电压有效值 u 从 90~140 V 之间变化,间隔 1 V 进行仿真,得到每类故障对应的 51 组波形样本,8 类故障共计 408 组。对每组样本进行时频分

表 3 时频特征总览表

Table 3 Summary table of time-frequency characteristics

标号	特征指标	标号	特征指标
1	均值	11	信号能量
2	标准差	12	方根幅值
3	偏度	13	WPD_E1
4	峰度	14	WPD_E2
5	峰峰值	15	WPD_E3
6	均方根	16	WPD_E4
7	振幅因数	17	WPD_E5
8	波形因数	18	WPD_E6
9	冲击因数	19	WPD_E7
10	裕度因数	20	WPD_E8

析,提取上述多维特征,构建故障特征集并对每维特征进行标准化处理。以主桥单上、下桥臂开路为例,标准化后部分特征集如表 4 所示,可见不同故障模式下特征差异较大,多维时频特征提取效果较好。

表 4 标准化后部分特征集

Table 4 Partial feature sets after normalization

特征	D ₁ 开路	D ₂ 开路	特征	D ₁ 开路	D ₂ 开路
1	0.948 8	1.512 0	11	0.945 7	1.508 0
2	0.647 3	0.752 6	12	0.948 3	1.580 7
3	0.056 2	0.056 1	13	0.948 8	1.581 4
4	-0.393 3	-0.393 2	14	0.663 8	1.378 5
5	0.864 3	0.994 2	15	0.732 9	0.143 4
6	0.954 4	1.519 3	16	0.964 9	0.481 1
7	0.165 0	0.165 0	17	0.928 9	1.515 3
8	0.161 1	0.162 2	18	0.071 3	2.169 7
9	0.164 1	0.164 2	19	1.736 9	-0.226 8
10	-0.870 8	-1.286 5	20	1.528 6	-0.646 7

2.3 故障诊断分析

满足训练集与测试集比例为 7 : 3,在每类特征集中随机选取 36 组特征向量共计 288 组作为训练样本,训练后得到 GA-BRBPNN 诊断模型,对其余 120 组特征向量进行测试,并对比测试样本真实情况,计算故障识别准确率。BP 神经网络隐层和输出层激活函数分别设为 logsig 和 purelin,根据式(4)设定隐层神经元节点数为 10,参数设定如表 5 所示。

$$N_h = \sqrt{N_{in} + N_{out}} + A \quad (4)$$

式中: N_h 为隐层神经元节点数, N_{in} 为输入层神经元节点数, N_{out} 为输出层神经元节点数, A 为经验常值,取值范围 1~10。根据神经网络 20-10-8 的结构可确定共需优化权值 280 个、阈值 18 个,经多次实验调整,得出遗传算法运行参数,如表 6 所示。

表 5 BP 神经网络参数

Table 5 BP neural network parameters

参数名称	数值设置
最大训练次数	1 000
学习速率	0.01
最小性能梯度	10^{-6}
最高失败次数	6
动量因子	0.01
训练目标最小误差	0.01

表 6 遗传算法运行参数

Table 6 Genetic algorithm operating parameters


参数名称	数值设置
迭代次数	200
种群数量	40
交叉概率	0.8
变异概率	0.2

在 GA 算法寻优迭代过程中,计算种群适应度值,其遗传进化曲线如图 6(a)所示。随着遗传迭代次数增加与种群更新,算法训练误差逐渐下降,初始权阈值也逐渐优化。适值在迭代 20 次后趋于平缓,迭代 55 次后达到最小,收敛速度较快。对于测试样本,单次训练 GA-BRBPNN 故障识别准确率可达 100%,测试集误差分布如图 6(b)所示,可见其测试误差均集中在零误差线附近,整体符合正态分布。


相同参数下经多次试验,应用文献[10]的 LM 算法训练 BP 神经网络诊断正确率在 72.50%~97.50%间波动,这是由于此法中网络的初始权值、阈值均为随机给出,易陷入局部最优,其与 GA-BRBPNN 算法诊断结果对比如图 7 所示。选用不同训练算法训练 GA-BPNN,单次训练各算法表现如表 7 所示,将各法的最优适应度值 F_b 、遗传收敛代数 I_g 、训练集识别率 A_{tr} 和测试集识别率 A_{te} 进行对比,可知贝叶斯正则化方法训练下的诊断算法收敛速度、分类精度及泛化能力较其他方法更优。不失一般性,统计 20 次诊断平均识别准确率作为最终诊断准确率,GA-BRBPNN 算法训练集和测试集识别准确率分别为 100%和 99.46%,二者相近。

在所建多维特征集上应用不同分类识别算法,可进一步证实 GA-BRBPNN 算法效果。召回率主要表征单类故障样本中被准确识别的比例,可作为评价诊断方法的重要指标。如表 7 所示,通过对比各方法的单类故障召回率均值及 20 次诊断平均识别准确率,不难得出本文算法对 ATRU 故障诊断效果更优。此处朴素贝叶斯算法由 MATLAB 分类学习工具箱实现,参数服从默认设置;决策树、随机森林与支持向量机算法^[22]均由 R 语言实现,经反复实验,决策树算法参数保持默认设置,随机森林算法 NumTrees 设置为 50,支持向量机算法中 cost 设置为 0.1,

γ 设置为 0.1。



(a) 遗传进化曲线
(a) The curve of genetic evolution



(b) 测试集误差分布
(b) Error distribution of the test sets

图 6 GA-BRBPNN 算法表现

Fig. 6 GA-BRBPNN algorithm performance

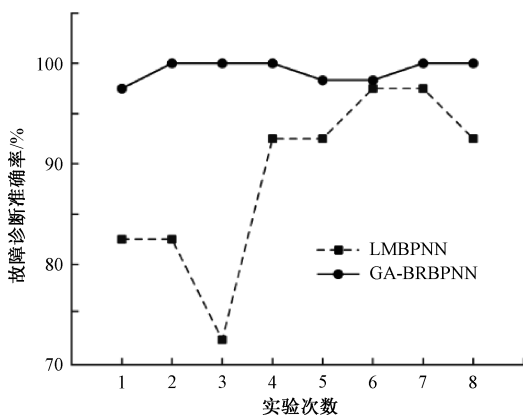


图 7 算法诊断结果对比

Fig. 7 Comparison of diagnostic results of algorithms

3 ATRU 故障诊断算法实验

3.1 ATRU 数据采集

ATRU 故障模拟实验平台如图 8 所示,主要由变频电源、18 脉波 ATRU、恒功率模拟负载和工控机组成, ATRU 柜体中包含故障模拟电路及数据采集电路。经实验测试,正常运行时 ATRU 输入输出特性均满足现行航

表 7 不同训练算法下 GA-BPNN 表现

Table 7 Performance of GA-BPNN with different training algorithms

训练算法	性能指标			
	F_b	I_g	$A_{tr}/\%$	$A_{te}/\%$
动量自适应学习率法	0.013 9	27	100	73.33
弹性反馈传播法	0.013 7	38	100	74.17
一步分割法	0.007 4	33	100	77.50
鲍威尔共轭梯度法	0.011 8	17	100	82.50
拟牛顿法	0.011 4	101	100	83.33
量化共轭梯度法	0.011 6	20	100	88.33
列文伯格-马夸尔特法	0.007 6	21	100	92.50
贝叶斯正则化法	0.008 2	20	100	100

表 8 基于不同方法的故障诊断

Table 8 Fault diagnosis based on different methods

(%)

故障分类方法	召回率均值	平均准确率
支持向量机	75.00	77.03
决策树	80.83	80.83
随机森林	83.33	83.33
朴素贝叶斯	84.17	84.40
本文算法	98.83	99.46




图 8 ATRU 故障模拟实验平台实物图

Fig. 8 The ATRU fault simulation experiment platform

空供电系统标准。该平台可完成自耦变压器匝间短路 1 匝、自耦变压器绕组开路、主桥单二极管开路、辅桥单二极管开路、双二极管开路共 5 种故障模拟。

整流桥故障下,以额定输入、带载 3 kW 时 EMI 滤波器后端 A 相电流 I_a 为例,验证 GA-BRBPNN 故障诊断算法有效性。采样频率设为 0.05 MHz, 3 种典型故障状态 I_a 波形如图 9 所示,可见其波形相近,不易区分。

3.2 故障诊断算法实验验证

将每种工况采集到的 I_a 信号以 0.02 s 时间尺度截取 60 个波形样本,将此 180 个样本按照 2.2 节所述提取多维时频特征,汇总成特征数据集,按 7 : 3 划分训练集

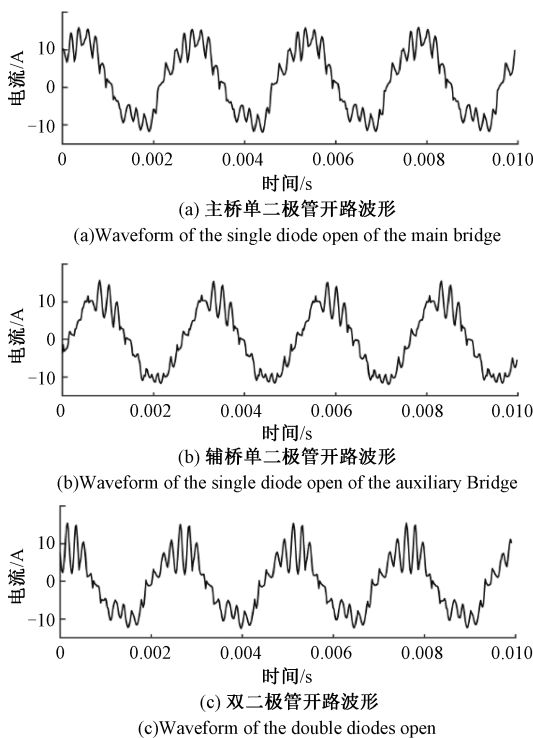


图9 实测故障波形

Fig. 9 Measured fault waveforms

和测试集,进而训练 GA-BRBPNN 模型并统计其故障诊断准确率。其中, BP 神经网络参数设置如表 5 所示,遗传算法运行参数如表 6 所示。算法对测试集样本诊断结果如图 10 所示,54 个待测样本均可正确识别,识别准确率 100%。图中样本类型 1 为主桥单二极管开路故障,类型 2 为辅桥单二极管开路故障,类型 3 为双二极管开路故障。




图 10 测试集故障诊断结果

Fig. 10 Fault diagnosis results for the test set

4 结 论

本文立足于关键航电设备故障诊断这一工程实际,

提出了一种基于 GA-BRBPNN 的故障分类识别方法,主要研究结论如下:1)不同故障模式下,采用时频分析方法得到的多维特征差异明显,可有效提高算法诊断效率和相近故障的分辨能力。2)GA-BRBPNN 故障诊断方法弥补了单一算法不足,其收敛速度、分类精度及泛化能力均优于对比算法,且在小样本数据训练下仍能取得较好诊断效果。3)通过搭建实验平台进行故障模拟,并用所提诊断方法对实测故障数据进行实验验证,准确率达到 100%,为相关故障诊断研究提供了一定的方法借鉴。

参考文献

[1] 陈杰,申朋朋,陈新,等. 新型可变升压比 18 脉波自耦变压整流器研究[J]. 电工技术学报,2018,33(15):3607-3616.
CHEN J, SHEN P P, CHEN X, et al. Research on a novel variable step-up ratio 18-pulse auto-transformer rectifier unit[J]. Transactions of China Electrotechnical Society, 2018,33(15):3607-3616.

[2] 李男,葛红娟,张璐,等. D 型不对称 24 脉自耦变压整流器设计[J]. 电工技术学报,2019,34(4):756-764.
LI N, GE H J, ZHANG L, et al. Design of D-type asymmetric 24-pulse auto-transformer rectifier [J]. Transactions of China Electrotechnical Society, 2019, 34(4):756-764.

[3] ABDOLLAHI R, GHAREHPETIAN GB. A 20-pulse auto-transformer rectifier unit for more electric aircrafts [J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2020,9(3):2992-2999.

[4] 石旭东,徐海义,吴东华,等. 基于 SDAE-PSOSVM 的航空变压整流器故障诊断方法研究[J]. 北京理工大学学报,2021,41(10):1069-1076,1083.
SHI X D, XU H Y, WU D H, et al. Fault diagnosis method for aviation transformer rectifier unit based on SDAE-PSOSVM[J]. Transactions of Beijing Institute of Technology, 2021,41(10):1069-1076,1083.

[5] 黄宇剑,林圣,吴鉴舟,等. 基于波形特征的地铁牵引整流器二极管开路故障诊断方法[J]. 电力自动化设备,2020,40(5):195-204.
HUANG Y J, LIN SH, WU J ZH, et al. Fault diagnosis method of diode open circuit in metro traction rectifier based on waveform characteristics [J]. Electric Power Automation Equipment, 2020,40(5):195-204.

[6] 陈丹江,叶银忠. 基于多神经网络的三电平逆变器器件开路故障诊断方法[J]. 电工技术学报,2013,28(6):120-126.
CHEN D J, YE Y ZH. Fault diagnosis of three level inverter based on multi neural network [J]. Transactions of China Electrotechnical Society, 2013, 28 (6) :

- 120-126.
- [7] 周晨阳,沈艳霞. 基于小波分析的三重三相电压型逆变器开路故障诊断[J]. 电机与控制学报, 2020, 24(9):65-75,94.
ZHOU CH Y, SHEN Y X. Open circuit fault diagnosis of dual three-phase voltage source inverter based on wavelet analysis [J]. Electric Machines and Control, 2020, 24(9):65-75,94.
- [8] 曹辉,杨理践,刘俊甫,等. 基于数据融合的小波变换漏磁异常边缘检测[J]. 仪器仪表学报, 2019, 40(12):71-79.
CAO H, YANG L J, LIU J F, et al. Magnetic flux leakage anomaly edge detection based on data fusion and wavelet transformation [J]. Chinese Journal of Scientific Instrument, 2019, 40(12):71-79.
- [9] 王俊波,武利会,罗容波,等. 基于小波变换—振动起始时刻分析的高压断路器故障诊断方法[J]. 高压电器, 2020, 56(6):211-217.
WANG J B, WU L H, LUO R B, et al. Fault diagnosis method of high voltage circuit breaker based on wavelet transform-vibration start time analysis [J]. High Voltage Apparatus, 2020, 56(6):211-217.
- [10] 宋志杰,王健. 模糊聚类和 LM 算法改进 BP 神经网络的变压器故障诊断[J]. 高压电器, 2013, 49(5):54-59.
SONG ZH J, WANG J. Transformer fault diagnosis based on BP neural network optimized by fuzzy clustering and LM algorithm [J]. High Voltage Apparatus, 2013, 49(5):54-59.
- [11] 赵文清,严海,周震东,等. 基于残差 BP 神经网络的变压器故障诊断[J]. 电力自动化设备, 2020, 40(2):143-148.
ZHAO W Q, YAN H, ZHOU ZH D, et al. Fault diagnosis of transformer based on residual BP neural network [J]. Electric Power Automation Equipment, 2020, 40(2):143-148.
- [12] 孔德钱,张新燕,童涛,等. 基于差分进化算法与 BP 神经网络的变压器故障诊断[J]. 电测与仪表, 2020, 57(5):57-61.
KONG D Q, ZHANG X Y, TONG T, et al. Transformer fault diagnosis based on differential evolution algorithm and BP neural network [J]. Electrical Measurement & Instrumentation, 2020, 57(5):57-61.
- [13] 赵玲玲,王群京,陈权,等. 基于 IBBOA 优化 BP 神经网络的变压器故障诊断[J]. 电工电能新技术, 2021, 40(9):39-46.
ZHAO L L, WANG Q J, CHEN Q, et al. Fault diagnosis of transformer based on BP neural network optimized by IBBOA [J]. Advanced Technology of Electrical Engineering and Energy, 2021, 40(9):39-46.
- [14] 曹阳,王金明,徐程骥,等. 基于 PID 和深度卷积神经网络的辐射源识别方法[J]. 数据采集与处理, 2020, 35(4):664-671.
CAO Y, WANG J M, XU CH J, et al. Specific emitter identification based on PID and deep convolutional neural network [J]. Journal of Data Acquisition and Processing, 2020, 35(4):664-671.
- [15] CHAHAR V, KATOCH S, CHAUHAN S S. A review on genetic algorithm: Past, present, and future [J]. Multimedia Tools and Applications, 2021, 80(5):8091-8126.
- [16] 胡超,沈宝国,杨妍,等. AdaBoost 算法组合的 GABP 诊断模型在轴承故障中的运用[J]. 机床与液压, 2021, 49(2):163-169.
HU CH, SHEN B G, YANG Y, et al. Application of GABP diagnostic model based on adaboost algorithms in bearing fault [J]. Machine Tool & Hydraulics, 2021, 49(2):163-169.
- [17] LUO J, GAN Y, VONG C M, et al. Scalable and memory-efficient sparse learning for classification with approximate bayesian regularization priors [J]. Neurocomputing, 2021, 457:106-116.
- [18] 高爽. 齿轮故障特征参数提取及最佳特征参数选择研究[D]. 沈阳:沈阳航空航天大学, 2017.
GAO SH. Research on fault feature extraction and optimal parameters selection for great [D]. Shenyang: Shenyang Aerospace University, 2017.
- [19] 赵光权,姜泽东,胡聪,等. 基于小波包能量熵和 DBN 的轴承故障诊断[J]. 电子测量与仪器学报, 2019, 33(2):32-38.
ZHAO G Q, JIANG Z D, HU C, et al. Bearing fault diagnosis based on wavelet packet energy entropy and DBN [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2):32-38.
- [20] 潘超,陈祥,蔡国伟,等. 基于小波包尺度-能量占比的变压器三相不平衡绕组振动特征辨识[J]. 仪器仪表学报, 2020, 41(4):129-137.
PAN CH, CHEN X, CAI G W, et al. Identification of winding vibration characteristics of three-phase unbalanced transformer based on scale-energy ratio of wavelet packet [J]. Chinese Journal of Scientific Instrument, 2020, 41(4):129-137.
- [21] 王一鹏,陈学振,李连玉. 基于小波包混合特征和支持向量机的机床主轴轴承故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(2):59-64.
WANG Y P, CHEN X ZH, LI L Y. Research on fault

diagnosis of machine spindle bearing based on wavelet packet mixing feature and SVM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2) :59-64.

- [22] 李典阳,张育杰,冯健,等. 变压器故障样本多维诊断及结果可信度分析[J]. 电工技术学报,2022,37(3) : 667-675.

LI D Y, ZHANG Y J, FENG J, et al. Multi-dimensional diagnosis of transformer fault sample and credibility analysis [J]. Transactions of China Electrotechnical Society, 2022,37(3) :667-675.

作者简介




董慧芬, 2006 年于北京航空航天大学获得博士学位, 现为中国民航大学副教授, 主要研究方向为航空电气装置故障诊断等。
E-mail: hfdong@cauc.edu.cn

Dong Huifen received her Ph. D. degree from Beihang University in 2006. Now she is

an associate professor in Civil Aviation University of China. Her main research interests include aero electric equipment fault

diagnosis etc.




郑坤(通信作者), 2019 年于华北理工大学获得学士学位, 现为中国民航大学硕士研究生, 主要研究方向为航空电气装置故障诊断等。

E-mail: 572875341@qq.com

Zheng Kun (Corresponding author)

received his B. Sc. degree from North China University of Science and Technology in 2019. Now he is a M. Sc. candidate in Civil Aviation University of China. His research interests include aero electric equipment fault diagnosis etc.



杨占刚, 2007 年于天津大学获得博士学位, 现为中国民航大学副教授, 主要研究方向为机载系统测试与故障诊断等。

E-mail: zgyang@cauc.edu.cn

Yang Zhangang received his Ph. D. degree from Tianjin University in 2007. Now

he is an associate professor in Civil Aviation University of China. His main research interests include airborne systems testing and fault diagnosis etc.