

DOI:10.19651/j.cnki.emt.2209134

基于 BCL-ASA-BP 神经网络的模拟 电路板芯片故障诊断*

王力^{1,2} 刘学朋^{1,2} 张亦弛^{1,2}

(1. 中国民航大学电子信息与自动化学院 天津 300300; 2. 中国民航大学机载电子系统深度维修实验室 天津 300300)

摘要: 针对模拟电路板芯片故障界定标准不明确和实现快速、准确分类困难的问题,本文提出了一种基于二元卷积 Logistic 原子搜索算法(BCL-ASA)优化 BP 神经网络(BCL-ASA-BP)的故障诊断模型。首先,对电路板芯片不同状态下的温度进行采集和特征提取,并采用欧氏距离对特征进行融合,建立含有芯片故障界定标准的故障特征模型。接着,利用二元卷积 Logistic 映射初始化原子搜索算法的种群规模和位置,提高收敛速度和精度。然后,通过 BCL-ASA 优化 BP 神经网络寻优过程,获得最优权值和阈值。最后,将芯片故障特征模型输入到 BCL-ASA-BP 神经网络中进行训练和测试,完成电路板芯片故障诊断。实验采用电源电路板进行可靠性分析,结果表明,BCL-ASA-BP 对芯片故障综合诊断准确率可达 98.35%,较传统 BP 算法提升 13.9%。

关键词: 二元卷积 Logistic 混沌映射;原子搜索算法;BP 神经网络;模拟电路板芯片;故障诊断

中图分类号: TN219 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Fault diagnosis of analog circuit board chip based on BCL-ASA-BP neural network

Wang Li^{1,2} Liu Xuepeng^{1,2} Zhang Yichi^{1,2}

(1. School of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China;

2. Deep Maintenance Laboratory of Airborne Electronic System, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aiming at the problems that the fault definition standard of analog circuit board chip is not clear and it is difficult to realize fast and accurate classification, this paper proposes a fault diagnosis model based on binary convolution logistic atom search algorithm to optimize BP neural network. Firstly, the temperature of circuit board chip in different states is collected and feature extracted, and the features are fused by Euclidean distance to establish a fault feature model containing chip fault definition criteria. Then, the binary convolution logistic map is used to initialize the population size and location of the atomic search algorithm to improve the convergence speed and accuracy. Then, the optimization process of BP neural network is optimized by BCL-ASA to obtain the optimal weight and threshold. Finally, input the chip fault characteristic model into the BCL-ASA-BP neural network for training and testing to complete the circuit board chip fault diagnosis. The experiment uses the power supply circuit board for reliability analysis, and the results show that the accuracy of BCL-ASA-BP's comprehensive diagnosis of chip faults reaches 98.35%, which is 13.9% higher than the traditional BP algorithm.

Keywords: binary convolution Logistic chaotic map; atomic search algorithm; BP neural network; analog circuit board chip; fault diagnosis

0 引言

目前,模拟电子电路广泛应用于通信、控制、导航等各

个电子系统中,随着对电子系统可靠性需求的不断提高,发展模拟电路故障诊断技术已成为当前电路测试领域的首要任务^[1]。

收稿日期:2022-03-02

* 基金项目:国家自然科学基金委员会与中国民用航空局联合资助基金(U1733119)、中央高校基本业务费项目(3122017107)、基于红外技术与数据驱动的机载电路板卡故障诊断与预测研究项目(2021YJS018)资助

由于传统故障诊断方法缺乏对故障类型界定标准做出明确定义,使得模型诊断准确率不稳定且诊断结果缺乏可解释性,这成为模拟电路故障诊断技术发展缓慢的重要原因^[2-4]。因此,近年来国内外对模拟电路故障诊断技术的研究力度逐步加大,单帅帅等^[5]提出基于小波包能量谱和独立成分分析的模拟电路故障诊断方法,该方法有效解决了模拟电路故障特征提取和故障分类问题。闫理跃^[6]将偏离元件正常值的变化量作为电路性能退化指示器,然后结合粒子群滤波器算法对其变化趋势做出预测,此模型虽然提出了故障指示器的概念但未将此标准用于模拟电路故障诊断中。杜先君等^[7]提出一种基于注意力机制与卷积神经网络^[8]的模拟电路故障诊断方法,该模型结合深度学习方法有效解决了模拟电路故障诊断准确率不高的问题。王浩天等^[9]和 Xuanyin 等^[10]提出了一种用遗传算法优化 BP 神经网络的电子系统故障诊断方法,通过遗传算法寻找神经网络最优权值和阈值,解决了 BP 神经网络陷入局部最优解的问题,提高了模型诊断精度,但模型训练时间较长;马峻等^[11]和 Cheng 等^[12]提出一种组合优化反向传播神经网络的故障诊断方法,该方法有效解决了模拟电路故障特征提取困难,诊断模型训练时间过长的问题。杨晓朋等^[13]和 Liang 等^[14]提出一种基于杂草算法优化多核支持向量机^[15]的故障诊断模型,该模型有效弥补了单核支持向量机易遗漏样本中有效信息,泛化能力差的缺陷,对故障实现了精准分类。

综上所述,针对模拟电路故障类型界定标准不明确和难以实现快速、准确分类的问题,本文将着力从以下两部分进行解决:1)建立故障指数模型,利用欧氏距离对故障特征进行融合得到可界定电路故障类型的指数,此指数可对电路故障类型实现精准划分;2)构建最优故障诊断模型,利用双元卷积 Logistic 原子搜索算法(binary convolution logistic-atom search algorithm, BCL-ASA)优化 BP 神经网络的寻优过程,建立 BCL-ASA-BP 神经网络故障诊断模型,从而对电路芯片故障实现快速诊断。最后选取稳压可调电源电路板对本文算法的诊断效果进行验证。

1 电路板芯片的故障特征提取

1.1 基于红外的芯片数据采集

传统故障数据获取方法是在故障点安装相应传感器并测量所需数据,此方法获取故障数据的效率低且极易对电路板造成二次损伤。红外数据获取是基于热辐射原理,通过监测元件表面温度变化完成数据采集,属于非接触式无损测量,具有检测速度快、成本低、通用性强以及易掌握等优点。本节将利用红外技术采集实验电路板上芯片的不同故障数据,方便后续对芯片故障数据进行特征提取。

红外温度数据采集系统主要由红外热像仪、传输总线、数控计算机、继电器和实验电路板构成。红外热像仪用来记录电路板实时温度数据;传输总线将采集的温度数据传

输给数控计算机;数控计算机则用来存储采集的数据。

芯片温度数据采集步骤如下:首先,设置电路板芯片故障类型,采集芯片不同状态下的温度数据;然后,选取芯片中心 10×8 个像素点作为其集中发热区域,得到如式(1)所示的芯片温度矩阵;最后,从温度矩阵中提取出芯片工作时最大、平均温度序列,建立芯片温度数据集。

$$\begin{bmatrix} T_{1,1} & T_{1,2} & \cdots & T_{1,8} \\ T_{2,1} & T_{2,2} & \cdots & T_{2,8} \\ \vdots & \vdots & \ddots & \vdots \\ T_{10,1} & T_{10,2} & \cdots & T_{10,8} \end{bmatrix} \quad (1)$$

1.2 数据预处理及特征提取

为有效研究芯片在不同故障状态下温度变化规律,本文将温度数据集预处理后得到了 7 个表征芯片温度曲线变化的特征值。

1) 芯片到达稳定工作温度时发热区域内最大温度增量 ΔT_{\max} :

$$\Delta T_{\max} = T_{\max} - T_c \quad (2)$$

式中: T_{\max} 为芯片到达稳定工作温度时发热区域内的最大温度, T_c 为室温。

2) 芯片到达稳定工作温度时发热区域内平均温度增量 ΔT_{avg} :

$$\Delta T_{\text{avg}} = T_{\text{avg}} - T_c \quad (3)$$

式中: T_{avg} 为芯片到达稳定工作温度时发热区域内的平均温度, T_c 为室温。

3) 芯片升温过程中发热区域最大温度曲线的一阶导数值 T'_{\max} :

$$T'_{\max} = \frac{\Delta T_{\max}}{m} \quad (4)$$

式中: m 为芯片发热区域内的最大温度到达稳定时红外摄影仪拍摄的图像数日。

4) 芯片升温过程中发热区域平均温度曲线的一阶导数值 T'_{avg} :

$$T'_{\text{avg}} = \frac{\Delta T_{\text{avg}}}{n} \quad (5)$$

式中: n 为芯片发热区域内的平均温度到达稳定时红外摄影仪拍摄的图像数目。

5) 芯片升温过程中发热区域最大温度曲线的二阶导数值 T''_{\max} :

$$T''_{\max} = \frac{(T_{\max} - T_{\max-1}) - (T_{\max1} - T_c)}{m-1} \quad (6)$$

式中: $T_{\max-1}$ 为芯片到达稳定工作温度前一时刻发热区域的最大温度值, $T_{\max1}$ 为电路板通电后芯片升温过程中发热区域内最大温度曲线初始时刻温度值。

6) 芯片升温过程中发热区域平均温度曲线的二阶导数值 T''_{avg} :

$$T''_{\text{avg}} = \frac{(T_{\text{avg}} - T_{\text{avg}-1}) - (T_{\text{avg1}} - T_c)}{n-1} \quad (7)$$

式中: T_{avg-1} 为芯片到达稳定工作温度前一时刻发热区域的平均温度值, T_{avg1} 为电路板通电后芯片升温过程中发热区域内平均温度曲线初始时刻温度值。

7) 芯片发热区域(10×8 个像素点)在一个工作周期内总发热量 S :

$$S = \left(\int_0^h T_{avg}(x) dx - h \cdot T_c \right) \cdot (10 \times 8) \quad (8)$$

式中: $T_{avg}(x)$ 为芯片在一个工作周期内其发热区域平均温度曲线的拟合函数, h 为芯片工作一个周期红外摄像机拍摄图像数日。

为方便后面对特征值进行融合,将以上 7 个表征芯片温度变化的特征值组成芯片故障特征向量 F :

$$F = [\Delta T_{max} \quad \Delta T_{avg} \quad T'_{max} \quad T'_{avg} \quad T''_{max} \quad T''_{avg} \quad S] \quad (9)$$

1.3 故障指数模型

为了进一步量化芯片在不同故障状态下的损耗情况,本文提出了一种融合芯片多个特征值的故障指数模型。

故障指数是反映电路性能退化程度或界定故障类型的数值,其会随着电路性能衰退程度或故障类型不同而改变。本文利用欧氏距离计算芯片正常状态特征与故障状态特征间的真实距离^[15],并用此距离作为界定芯片故障类型的标准。

假设芯片正常状态下的特征向量为 $F_0 = [\Delta T_{max}^0 \quad \Delta T_{avg}^0 \quad T'_{max}{}^0 \quad T'_{avg}{}^0 \quad T''_{max}{}^0 \quad T''_{avg}{}^0 \quad S^0]$, 故障状态下的特征向量为 $F_n = [\Delta T_{max}^n \quad \Delta T_{avg}^n \quad T'_{max}{}^n \quad T'_{avg}{}^n \quad T''_{max}{}^n \quad T''_{avg}{}^n \quad S^n]$, 则此时芯片的故障指数为:

$$D(F_0, F_n) = \sqrt{(\Delta T_{max}^0 - \Delta T_{max}^n)^2 + \dots + (S^0 - S^n)^2} \quad (10)$$

2 BCL-ASA-BP 故障诊断模型

2.1 BP 神经网络

以 3 层 BP 神经网络为例,其结构组成,如图 1 所示。




图 1 3 层 BP 神经网络结构

从图 1 中可以看出, BP 神经网络训练过程包含正向传递和误差反向传递两个步骤,其中误差反向传递是使其实

现误差自动修正的关键步骤。误差反向传递是将不满足设定要求的输出误差信号反向传递至输入层,随后对权值 w_{ij} 和阈值 b_i 进行修订,经反复学习和训练后,获得期望输出值,建立最优 BP 神经网络。

BP 神经网络虽然能较好的解决非线性问题和实现误差自动修正,但随着问题复杂度的增加,它的不足也突显出来,主要有如下两点:

1) 由于 BP 神经网络对权值变化量 $\Delta w_{ji}(z)$ 的修正采用梯度下降法,当全部瞬间误差 $E(z)$ 波形振动频繁时, BP 神经网络寻优极易陷入局部最优的困境;

2) BP 神经网络寻优过程对 α 的大小要求非常苛刻,学习率过小致使模型训练时间长,学习率过大会使权值变化量不稳定,出现 1) 中 $E(z)$ 振荡现象^[17]。

2.2 原子搜索算法

为解决 BP 神经网络存在的问题,本文采用原子搜索算法对其寻优过程进行优化。原子搜索算法是一种通过原子间相互作用力和系统对各原子约束力致使原子产生定向运动的智能优化算法,与梯度下降算法不同,它不仅可以解决学习率大小难以选取的问题,还可同时对多组局部最优解进行优化、比较,最终从众多解中寻得全局最优解,在保证寻得 BP 神经网络最佳权值、阈值解的同时,极大限度的缩短了寻优时间,较好的弥补了 BP 神经网络的不足。

假设一个分子系统是由 d 维空间中的 s 个原子构成,根据牛顿第二定律,第 i 个原子在第 t 次迭代时的加速度为:

$$a_i^d(t) = \frac{F_i^d(t) + G_i^d(t)}{m_i^d(t)} \quad (11)$$

式中: $F_i^d(t)$ 为第 t 次迭代时 d 维空间中作用于第 i 个原子的总力, $G_i^d(t)$ 为第 t 次迭代时 d 维空间中全局最优原子对第 i 个原子的几何约束作用, $m_i^d(t)$ 为第 t 次迭代时 d 维空间中第 i 个原子的质量。

最优原子速度更新公式为:

$$v_i^d(t+1) = rand^d v_i^d(t) + a_i^d(t) \quad (12)$$

最优原子位置更新公式为:

$$X_i^d(t+1) = X_i^d(t) + v_i^d(t+1) \quad (13)$$

式中: $X_i^d(t)$ 为第 i 个原子在第 t 次迭代时的位置。

从式(11)~(13)可看出,原子搜索算法寻优核心是对局部最优原子加速度、速度和位置循环更新直至寻得全局最优原子的过程,这不仅能够解决传统 BP 神经网络易陷入局部最优的问题还保证了原子搜索算法寻优结果的收敛性。但原子搜索算法的寻优过程受初始参数影响较大,常会因为种群分布不均匀或种群规模设置不当而出现“早熟”现象和收敛速度慢的问题。

2.3 二元卷积 Logistic 混沌映射

针对上节提出的原子搜索算法的不足,本文提出一种二元卷积 Logistic 混沌映射模型,利用此模型产生的均匀序列初始化原子搜索算法的种群数目和位置参数,确保搜

索算法能以一条理想的寻优路线向全局最优解靠近,从而加速最佳故障诊断模型的建立。

二元卷积 Logistic 混沌映射是在一维 Logistic 混沌映射基础上改进而来,其产生的序列相较于一维 Logistic 映射序列分布更均匀,可以对原子搜索算法起到更好的优化作用,具体设计步骤如下。

Logistic 混沌属于非线性动力学系统,它产生的映射序列具有随机、非周期和收敛的特性。一维 Logistic 映射数学表达式为:

$$x(t+1) = \mu x(t)[1-x(t)] \quad (14)$$

式中: $x(t)$ 为映射序列,取值介于 $[0,1]$ 区间内, t 为迭代次数, μ 为 Logistic 参数,介于 $[0,4]$ 区间内。

图2为 $\mu = 3.99, x(1) = 0.5$ 和 $t = 3000$ 时一维 Logistic 混沌映射产生的序列分布图。




图2 一维 Logistic 混沌映射序列分布图

可以看出,此时的序列除在 $x(t) = 0.15$ 与 $x(t) = 1$ 边缘有两条聚集带外,在 $x(t) = 0.1$ 附近还留有大量空白,分布极为不均匀,所以此时 Logistic 混沌映射产生的序列不能满足均匀初始化原子搜索算法参数的要求。

为使 Logistic 混沌映射产生一个均匀遍历 $[0,1]$ 的序列,本文提出一种二元卷积 Logistic 混沌映射模型。

首先对一维 Logistic 混沌映射模型进行扩维,

$$\begin{cases} x(t_1+1) = \mu_1 x(t_1)[1-x(t_1)] \\ h(t_2+1) = \mu_2 h(t_2)[1-h(t_2)] \end{cases} \quad (15)$$

式中: μ_1, μ_2 分别为序列 $x(t_1)$ 与 $h(t_2)$ 的 Logistic 参数且

$$\begin{cases} \mu_1 = 3.99, & \begin{cases} x(1) = 0.5 \\ h(1) = 0.5 \end{cases} \text{ 和 } \begin{cases} t_1 = 1501 \\ t_2 = 1500 \end{cases} \\ \mu_2 = 3.99 \end{cases}$$

然后将序列 $x(t_1)$ 与 $h(t_2)$ 卷积后取正弦得:

$$g(t_3) = \sin(x(t_1) \otimes h(t_2)) \quad (16)$$

式中: $t_3 = t_1 + t_2 - 1$

综上,对 $g(t_3)$ 作 Logistic 映射变换得,

$$y(t_3) = \mu_3 g(t_3)[1-g(t_3)] \quad (17)$$

图3为 $\begin{cases} \mu_3 = 3.99 \\ t_3 = 3000 \end{cases}$ 时 $y(t_3)$ 产生的序列分布图。




图3 二元卷积 Logistic 映射序列分布图

由图2和3可以看出,相较于一维 Logistic 混沌映射,二元卷积 Logistic 混沌映射产生的序列在保证自身收敛的情况下分布更为均匀。因此,利用二元卷积 Logistic 映射序列的随机、均匀和非周期特性初始化原子搜索算法的种群规模与位置,可以使原子搜索算法避免因初始参数设置不当而出现“早熟”现象和收敛速度慢的问题。

2.4 BCL-ASA-BP 建立过程

首先建立标准的 BP 神经网络模型,将式(9)所示的芯片故障特征向量传递给输入层神经元,输入层神经元个数由特征向量中特征值数目决定,隐藏层神经元个数依据算法训练结果决定,输出层神经元为界定芯片故障类型的指数;然后利用二元卷积 Logistic 映射初始化原子搜索算法状态参数;最后,采用改进后的原子搜索算法代替梯度下降法寻找 BP 神经网络最佳权值和阈值,建立一个最优 BP 神经网络故障诊断模型,最佳模型形成过程可分为以下两部分。

1) ASA 参数初始化

利用二元卷积 Logistic 映射产生 $a \times b$ 个个体,选取其中适应度最佳的 b 个个体作为原子搜索算法的初始种群,种群的位置由二元卷积 Logistic 映射产生序列的先后顺序决定。通过保证原子搜索算法初始种群的随机性和均匀性,从而使原子搜索算法快速、精确寻得最优原子。

2) 寻优函数

为使 BCL-ASA 能寻得 BP 神经网络最优权值和阈值,本文选取均方误差为寻优函数,即在寻优过程中预测结果的均方误差越小,则此时 BP 神经网络的权值、阈值越接近最优。

$$MSE = \frac{1}{N} \sum_{i=1}^N (f_i - y_i)^2 \quad (18)$$

式中: N 为训练样本集的数量, f_i 为芯片故障指数真实值, y_i 为故障指数预测值。

模型建立具体步骤如下:

(1)利用红外技术采集芯片在不同状态下的温度数据,并对数据故障特征进行提取。

(2)建立标准 BP 神经网络模型并初始化其权值和阈

值,然后输入芯片故障特征数据。

(3)利用二元卷积 Logistic 映射对原子搜索算法的种群规模,个体位置和最大迭代次数等状态参数进行初始化。

(4)计算各原子初始适应度,选取适应度最佳原子作为当前最优原子,然后更新各原子加速度、速度和位置,重新计算、比较原子适应度值,更新最优原子位置。

(5)若当前最优原子能满足算法设定误差或达到最大迭代次数,则结束对最优原子的搜索,若未达到设定条件则跳转到步骤(4)继续寻找全局最优原子。

(6)当满足设定误差或达到最大迭代次数时,原子搜索算法输出 BP 神经网络最优权值、阈值,并构建最优故障诊断模型。

(7)输出最优模型的分类结果。

优化算法的流程如图 4 所示。

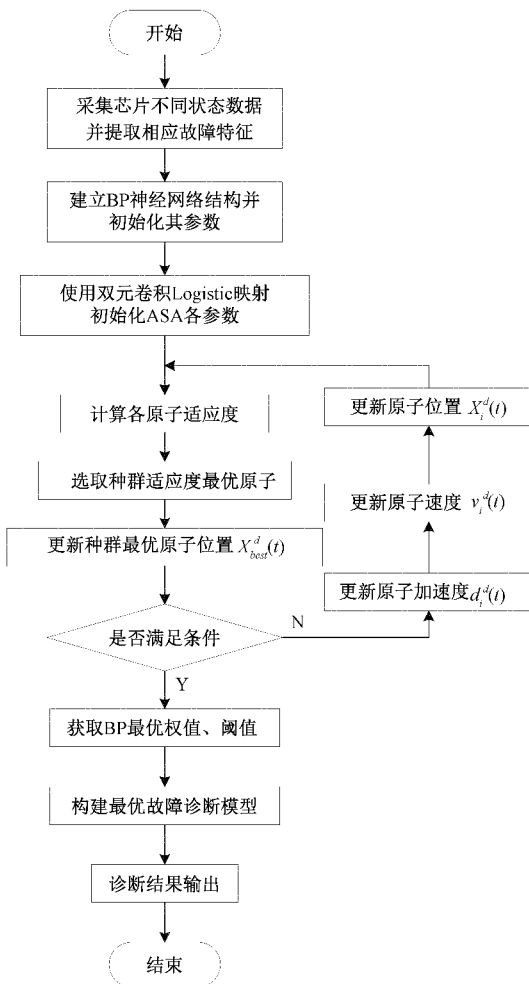


图 4 优化算法流程

3 故障诊断实验与分析

3.1 数据采集及故障类型设置

本文实验所用红外热像仪为英福泰克 (InfraTec)

ImageIR[®] 5300 系列,热灵敏度在 30 °C 时为 0.015 K,红外热像仪分辨率为 320×256。

实验电路是一块 0~30 V 直流稳压可调电源模拟电路,实验对象是电源电路板上的 U1 芯片,实验电路板红外图像及 U1 芯片位置如图 5 所示。




图 5 实验电路板红外图像

本文对芯片的故障诊断实验分为 10 V 1 020 Ω 和 30 V 1 020 Ω 两种工作状况进行。根据芯片引脚功能,对每种工作状况设置 8 种不同的故障,其中包含引脚断路和短路故障,且每种工况包括正常数据 100 组,8 种故障数据各 100 组,共 900 组实验数据,将其中 720 组数据划分为训练样本,用于对分类模型进行训练,剩余的 180 组数据作为测试样本,用于检验模型诊断准确率。

实验数据采集步骤如下:实验中将时间继电器通电时长设为 30 min,断电时长设为 10 min,以此作为芯片的一个工作周期,芯片在此期间会经历通电升至稳定温度,平稳工作一段时间后断电降至室温的过程;红外热像仪拍摄图像数目设置为 6 000 张,拍摄频率设为 2 s/张,即拍摄时长为 200 min,包含芯片 5 个工作周期。

获得实验数据后,经本文 1.2 和 1.3 节对其进行故障特征提取和故障指数计算的相应处理,最终得到两种工况下芯片的故障编号、类型和故障指数如表 1 所示。

表 1 两种工况下芯片的故障标记与指数

故障编号	故障类型	10 V 1 020 Ω	30 V 1 020 Ω
		故障指数	故障指数
F0	正常	0	0
F1	2 引脚断路	4.285~4.395	1.379~1.451
F2	3 引脚断路	3.769~3.949	1.139~1.171
F3	4 引脚断路	1.725~1.816	3.464~3.537
F4	6 引脚断路	9.191~9.355	10.784~11.357
F5	7 引脚断路	15.765~16.226	16.905~17.500
F6	23 引脚短路	2.964~3.056	2.701~2.790
F7	34 引脚短路	5.420~5.522	5.017~5.275
F8	67 引脚短路	3.294~3.429	2.908~2.983

3.2 实验结果与分析

为验证本文所提模型故障诊断准确率,选取了传统BP神经网络、原子搜索算法优化BP神经网络(ASA-BP)、粒子群优化支持向量机(PSO-SVM)和一维卷积神经网络(1D-CNN)进行对比实验。将10 V 1 020 Ω和30 V 1 020 Ω的故障特征分别输入到5种诊断模型中进行训练和测试。诊断结果如图6~11所示。




图6 10 V 1 020 Ω 工况芯片故障分类混淆矩阵图




图7 30 V 1 020 Ω 工况芯片故障分类混淆矩阵图

图6和7是为显示本文所提方法对芯片各类故障诊断准确率而搭建的混淆矩阵。从图中可以看出,本文方法对两种工况下芯片各类故障诊断准确率均在96.6%以上,说明本文所提模型能有效识别此模拟电路U1芯片各类常见故障,具有较好的泛化能力;因故障F1与F2、F6与F8对应的故障指数相差较小,所以导致算法对此4种故障诊断效果欠佳。

图8和9是为对BP、ASA-BP和BCL-ASA-BP 3种相同类别模型的故障诊断效果形成对照而从测试集中随机抽取90组数据进行实验得到的诊断结果。从图8和9中可




图8 10 V 1 020 Ω 3种同类别模型诊断结果对比

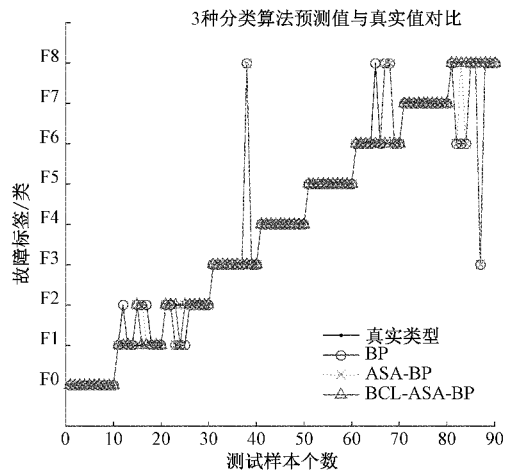


图9 30 V 1 020 Ω 3种同类别模型诊断结果对比

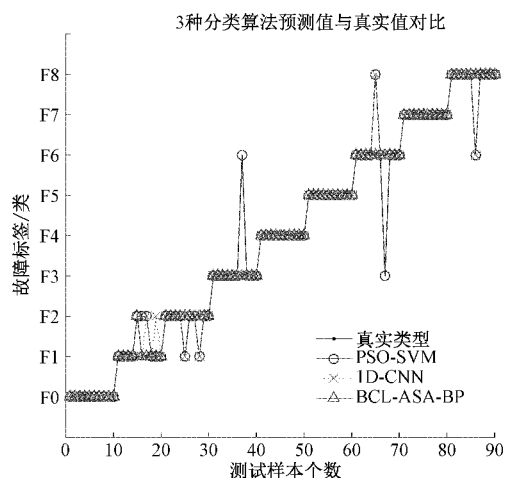


图10 10 V 1 020 Ω 3种不同类别模型诊断结果对比

以明显看出,3种模型对芯片故障的误诊同样多集中在F1和F2、F6和F8四类故障上,但经仔细对比可发现,BCL-ASA-BP对芯片故障的误诊数日要远小于前两种算法。




图 11 30 V 1 020 Ω 3 种不同类别模型诊断结果对比

为进一步显示本文所提模型在芯片故障诊断实验中较其他类传统算法有更好的诊断效果,图 10 和 11 给出了

PSO-SVM、1D-CNN 和包括本文算法在内 3 种不同类别模型的诊断结果。从图 10 和 11 中可以看出,这 3 种模型对芯片故障的误诊情况虽然与图 8 和 9 中略有不同,但同样可以得到本文算法对芯片故障的误诊数目要远小于 PSO-SVM 和 1D-CNN 的结论。因此,与四种对照模型相比,本文所提方法对芯片各类故障具有更好的分类效果。

为对上述 5 种模型诊断效果进行更加详细比较,表 2 给出了 5 种模型在两种工况下的模型训练时间、达到设定误差进行的最大迭代次数和诊断准确率的对比数据。从表中可以得出,本文所提算法对两种工况的各类故障综合诊断准确率高达 98.35%,1D-CNN、ASA-BP 和 PSO-SVM 次之,综合诊断准确率分别为 92.25%、89.5%和 89.35%,传统 BP 分类效果最差,综合诊断准确率仅 84.45%;且在训练时间上,本文所提模型训练时间比 ASA-BP、PSO-SVM 和 1D-CNN 模型分别提升了 41%、42.1%和 47.8%,较传统 BP 模型提升了 64%,为实现电路板芯片故障快速诊断提供了保障。

表 2 5 种模型对芯片两种工况的故障诊断效果对比

诊断模型	10 V 1 020 Ω			30 V 1 020 Ω		
	训练时间/s	迭代次数	准确率/%	训练时间/s	迭代次数	准确率/%
BP	300.6	114	85.6	330.3	146	83.3
ASA-BP	180.9	56	90.3	206.8	68	88.7
PSO-SVM	183.1	57	90.1	211.7	70	88.6
1D-CNN	193.8	63	93.3	248.1	82	91.2
BCL-ASA-BP	110.4	12	98.9	117.6	13	97.8

4 结 论

本文提出基于 BCL-ASA-BP 的模拟电路板芯片故障诊断模型,旨在通过确定电路板芯片故障指数进而实现对其故障快速、准确分类。首先,借助欧氏距离融合芯片多个状态特征值,得到能够界定芯片故障类型的指数。然后,采用二元卷积 Logistic 原子搜索算法优化 BP 神经网络的寻优过程,得到 BCL-ASA-BP 故障诊断模型。最后,将含有故障指数的特征数据输入到最优诊断模型中,根据预测出的故障指数完成对芯片故障的分类。从实验结果来看,本文所提算法综合故障诊断率可达 98.35%,优于 BP 神经网络故障诊断率 13.9%,在训练时间上,本文模型相较于 BP 神经网络模型也有较大程度提升;从理论层面来看,该模型改变了传统分类算法仅通过故障标签对故障进行分类的诊断方式,它是一种借助预测芯片故障指数以完成对芯片故障类型划分的诊断方式,为深层剖析故障信息进而确定芯片故障类型提供了一种新思路。

参考文献

[1] 高明哲,许爱强,唐小峰,等. 基于多核多分类相关向量的模拟电路故障诊断方法[J]. 自动化学报, 2019,

45(2): 434-444.

[2] 余萍,曹洁. 深度学习在故障诊断与预测中的应用[J]. 计算机工程与应用, 2020, 56(3): 1-18.

[3] 向刚,韩峰,周虎,等. 数据驱动的航天器故障诊断研究现状及挑战[J]. 电子测量与仪器学报, 2021, 35(2): 1-16.

[4] 李光升,欧博,石海滨. 现代模拟电路故障诊断技术发展综述[J]. 计算机测量与控制, 2019, 27(5): 5-8.

[5] 单帅帅,马清峰,谢雯鑫. 基于小波包能量谱和 ICA 的模拟电路故障特征提取方法[J]. 电子测量技术, 2021, 44(18): 19-23.

[6] 闫理跃. 基于退化特征分析的模拟电路剩余有效性能预测方法研究[D]. 成都:电子科技大学, 2018.

[7] 杜先君,巩彬,余萍,等. 基于 CBAM-CNN 的模拟电路故障诊断研究[J/OL]. 控制与决策, 1-9[2022-07-27]. DOI:10.13195/j.kzyjc.2021.1111.

[8] 宫文峰,陈辉,张美玲,等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 195-205.

[9] 王浩天,单甘霖,段修生. 基于遗传 BP 网络的模拟电路故障诊断[J]. 机械科学与技术, 2014, 33(12):

- 1888-1892.
- [10] XUANYIN W, XIAOXIAO L, FUSHANG L. Analysis on oscillation in electro-hydraulic regulating system of steam turbine and fault diagnosis based on PSOBP[J]. Expert Systems with Applications, 2010, 37(5): 3887-3892.
- [11] 马峻,赵飞乐,徐潇,等. MRA-PCA-PSO 组合优化 BP 神经网络模拟电路故障诊断研究[J]. 电子测量与仪器学报, 2018, 32(3): 73-79.
- [12] CHENG Y, LIN M, WU J, et al. Intelligent fault diagnosis of rotating machinery based on continuous wavelet transform-local binary convolutional neural network [J]. Knowledge-Based Systems, 2021, 216(1), DOI:10.1016/j.knsys.2021.106796.
- [13] 杨晓朋,陈伟,王鹏展,等. 基于 DCCA-IWO-MKSVM 的模拟电路故障诊断方法[J]. 计算机应用与软件, 2020, 37(1): 271-276.
- [14] LIANG H, ZHU Y, ZHANG D, et al. Analog circuit fault diagnosis based on support vector machine classifier and fuzzy feature selection[J]. Electronics, 2021, 10(12), DOI:10.3390/electronics10121496.
- [15] 王文凯,邓斌. 基于 DAE-IPSO-SVM 的电缆早期故障识别方法[J]. 国外电子测量技术, 2021, 40(8): 29-35.
- [16] 王力,龚振东. 基于多特征的 APSO-SVR 的模拟电路故障预测[J]. 云南大学学报(自然科学版), 2021, 43(4): 663-670.
- [17] MIAO M, JIANG J. Analog circuit fault diagnosis method based on optimized BP neuralnetwork [J]. International Journal of Digital Content Technology and its Applications, 2013, 7(6): 774-781.

作者简介

王力, 研究生导师, 教授, 主要研究方向为航空电子系统维修技术与方法。

E-mail: 43464376@qq.com

刘学朋, 硕士研究生, 主要研究方向为航空电子系统维修技术与方法。

E-mail: 1017331305@qq.com

张亦弛, 男, 硕士研究生, 主要研究方向为航空电子系统维修技术与方法。

E-mail: 1016139883@qq.com