

文章编号:1001-5078(2024)04-0574-10

· 红外技术及应用 ·

# 基于红外的 TPA 和 IA OA-BiLSTM 电路芯片故障诊断

王力, 朱猛, 马江燕

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

**摘要:** 为了提高电路芯片故障诊断准确率, 超参数设置的效率以及特征提取效率, 提出一种基于时间模式注意力机制(TPA)的改进算数优化算法(IAOA)优化双向长短期记忆网络(BiLSTM)的电路故障诊断方法。首先, 利用IAOA搜寻BiLSTM的最优超参数组合, 提高模型诊断精度; 然后使用TPA提取重要特征并分配权重, 改善模型特征提取能力; 最后, 将红外摄像头采集的红外温度数据输入到最优诊断模型中, 实现电路芯片故障诊断。实验采用0~30 V可调稳压电源电路进行验证。结果表明, 该模型对电路芯片故障诊断准确率高达98.27%, 可实现对电路芯片的高准确率故障诊断。

**关键词:** 红外技术; 芯片故障诊断; 双向长短期记忆网络; 算数优化算法; 时间模式注意力机制  
**中图分类号:** TP219; TP274 **文献标识码:** A **DOI:** 10.3969/j.issn.1001-5078.2024.04.014

## Fault diagnosis of TPA and IA OA-BiLSTM circuit chips based on infrared

WANG Li, ZHU Meng, MA Jang-yan

(Airborne Electronic Systems Deep Maintenance Laboratory, College of Vocational Technology, Civil Aviation University of China, Tianjin 300300, China)

**Abstract:** To improve the accuracy of circuit chip fault diagnosis, the efficiency of hyperparameter setting and the efficiency of feature extraction, an improved arithmetic optimization algorithm (IAOA) based on temporal pattern attention mechanism (TPA) is proposed to optimize the bi-directional long and short-term memory network (BiLSTM) for circuit fault diagnosis. Firstly, IAOA is employed to search for the optimal hyperparameter combinations of BiLSTM to improve the diagnostic accuracy of the model. Then TPA is used to extract important features and assign weights to enhance the model feature extraction capability. Finally, the infrared temperature data collected by the infrared camera is inputted into the optimal diagnostic model to achieve circuit board chip fault diagnosis. The experiments are verified by using 0~30 V adjustable regulated power supply circuit board. The results show that the model for circuit chip fault diagnosis is as high as 98.27%, which can achieve high accuracy fault diagnosis for circuit board chips.

**Keywords:** infrared technology; chip fault diagnosis; long short-term memory network; arithmetic optimization algorithm; temporal pattern attention mechanism

### 1 引言

随着模拟电路在现代电子系统中的高度集成和

广泛应用, 电路芯片的各种故障频繁出现。为了维护和保持系统可靠性、稳定性, 对模拟电路芯片进行

**基金项目:** 民航安全能力建设基金项目(No. [2023]50, 复杂环境下“黑匣子”搜寻探测与深度数据提取装备研制)资助。  
**作者简介:** 王力(1973-), 男, 博士, 教授, 研究生导师, 主要从事航空电子系统维修技术与方法研究。E-mail: 43464376@qq.com  
**通讯作者:** 朱猛(1999-), 男, 硕士研究生, 主要从事航空电子系统维修技术与方法研究。E-mail: 1935427533@qq.com  
**收稿日期:** 2023-06-05

精确的故障诊断已经成为了一个亟待解决的问题<sup>[1-3]</sup>。在实际使用中,电路芯片故障具有非线性、容差性等特征<sup>[4-5]</sup>,致使传统的故障诊断方法不适于当今的复杂电路。由于人为操作不当、供电电压不稳、工作环境恶劣等原因,电路芯片可能会出现不同程度、不同类型、不同位置的过压损坏、过载损坏、短路或断路等多种故障。

近年来,针对这些问题,国内外众多学者进行了相关研究。基于红外的非接触式故障诊断技术利用红外摄像机采集红外温度数据,并通过温度信息对电路芯片进行故障诊断,为电子系统的故障诊断提供了新的途径<sup>[6]</sup>。吕昂<sup>[7]</sup>等人提出了一种方法,通过分割红外图像发热区域,并使用最小二乘法拟合计算发热元器件表面温度和内部 PN 结温度来检测故障。谢晓怀<sup>[8]</sup>等人利用改进后的麻雀搜索算法优化 BP 神经网络来诊断电路芯片故障。姜也<sup>[9]</sup>等人通过构建卷积神经网络(CNN)模型实现了对 PC-BA 板载 DDR 芯片焊点缺陷的检测研究。王洋<sup>[10]</sup>等人通过采集旋转机械表面温度,并使用红外成像与增强方法来诊断旋转机械故障。Mehra R<sup>[11]</sup>等人使用二维离散小波变换处理红外电路图,并通过主成分分析提取特征,最后利用 SVM 实现故障诊断。余萍<sup>[12]</sup>等人利用蜜獾算法优化注意力双向长短期记忆网络(HBA-A-BiLSTM)实现了对轴承的故障诊断。Nacer S<sup>[13]</sup>利用改进的 BiLSTM 网络方法来诊断轴承故障,并提高了诊断准确率。

在上述的基础上,本文利用红外技术获取电路芯片温度数据,并提出了一种基于 TPA 和 IA OA-BiLSTM 的方法。首先,利用红外摄像机采集电路芯片温度数据,并形成数据集;其次,利用 BiLSTM 算法从不同方向提取故障数据中的主要特征;通过 IA OA 的优化搜索,构建最优参数组合的故障诊断模型;最后,结合 TPA 机制,诊断模型能够更有效的选择重要特征,提高诊断能力。与目前基于深度学习的电路故障诊断算法相比,本文算法在自建电路故障温度数据集上展现出了更好的故障诊断性能。

## 2 基础算法原理

### 2.1 双向长短期记忆网络

长短期记忆网络(LSTM)是在加入了门控机制的循环神经网络的基础上发展而来的,它解决了梯度消失和时间延迟的问题。然而,LSTM 只能学习

前向历史信息,而无法学习后向信息。为了更好地利用长时段的特征信息,本文采用双向长短期记忆网络 Bi-directional Long Short-Term Memory, BiLSTM)。它由前向 LSTM 和后向 LSTM 共同构成,前向 LSTM 获取输入序列的过去信息,后向 LSTM 获取输入序列的未来信息,实现过去未来信息的充分利用。BiLSTM 的结构如图 1 所示,其更新公式为:

$$\begin{cases} \vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = LSTM(x_t, \overleftarrow{h}_{t+1}) \\ y_t = W_{h_y}^{\rightarrow} \vec{h}_t + W_{h_y}^{\leftarrow} \overleftarrow{h}_t + b_y \end{cases} \quad (1)$$

式中,  $W_{h_y}^{\rightarrow}$  和  $W_{h_y}^{\leftarrow}$  为权重矩阵;  $b_y$  为偏置参数。

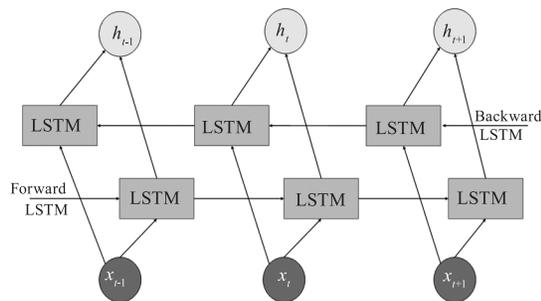


图 1 BiLSTM 网络结构图

Fig. 1 BiLSTM network structure diagram

### 2.2 时序模式注意力机制

时序模式注意力机制<sup>[14]</sup> (Temporal Pattern Attention mechanism, TPA) 利用卷积神经网络滤波器提取输入信息中的定长时序模式,使用评分函数确定各时序模式的权值,根据权值的大小得到最后的输出信息。

由于电路芯片存在多种故障类型,每种不同类别的故障数据中都包含多个变量。这些变量之间存在着相同或者相似的故障特征和复杂的非线性内在联系,并且每个故障数据序列都有自己独特的特征和周期变化,通过 TPA 与 BiLSTM 结合,诊断模型可以从不同时间步上学习多特征之间相互区别关系。TPA 机制的示意图如图 2 所示。

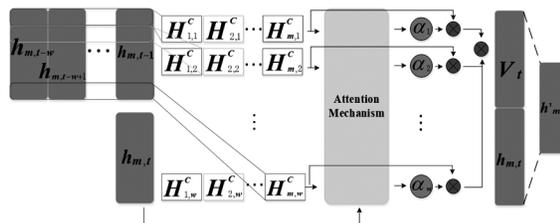


图 2 TPA 机制

Fig. 2 TPA mechanism

### 2.3 AOA 介绍

算数优化算法 (Arithmetic Optimization Algorithm, AOA) 是由 Abualigah<sup>[15]</sup> 等人于 2021 年提出的一种利用四则运算进行优化的元启发式算法。该算法利用乘除运算扩大算法全局搜索的分散性, 利用加减运算提高局部搜索的精确性, 具有一定得求解精度和较好的稳定性。

1) 数学优化器加速函数 (MOA)。AOA 使用数学优化器加速函数来选择搜索阶段, 当  $r_1 > MOA(t)$  时, 进行全局探索阶段; 否则, 进行局部开发阶段,  $r_1$  代表 0 到 1 之间的随机数。

MOA 数学模型公式如下:

$$MOA(t) = Min + t \times \frac{Max - Min}{T} \quad (2)$$

式中,  $t, T$  是当前迭代次数和最大迭代次数;  $Min$  和  $Max$  是加速函数的最小和最大值, 分别取 0.2 和 1.0。

2) 全局搜索阶段。在此阶段, AOA 主要采取乘除搜索策略以增加全局搜索的多样性, 并搜寻最优解。当  $r_2 < 0.5$  时, 执行除法搜索策略; 否则执行乘法搜索策略, 其位置更新公式如下:

$$X(t+1) = \begin{cases} \frac{X_b(t)}{MOP(t) + \varepsilon} \times L, r_2 \leq 0.5 \\ X_b(t) \times MOP(t) \times L, r_2 > 0.5 \end{cases} \quad (3)$$

$$L = ((UB - LB) \times \mu + LB) \quad (4)$$

式(3)中,  $r_2 \in [0, 1]$ ,  $\mu$  是调整搜索过程的控制参数, 值为 0.499;  $\varepsilon$  是一个很小的整数, 其作用是防止分母为 0;  $UB$  和  $LB$  分别代表着搜索空间的上界和下界;  $X(t+1)$  是  $t+1$  次迭代的位置;  $X_b(t)$  是目前候选解中最优解的位置。数学优化器的概率计算公式如下:

$$MOP(t+1) = 1 - \frac{t^{\frac{1}{\alpha}}}{T^{\frac{1}{\alpha}}} \quad (5)$$

式中,  $\alpha$  是一个敏感参数, 取值大小为 5。

3) 局部搜索阶段。在此阶段 AOA 主要采用加减搜索策略降低解的离散性, 提高算法的局部搜索能力。当  $r_3 < 0.5$ , 使用减法运算, 否则使用加法运算。其位置更新公式如下:

$$X(t+1) = \begin{cases} X_b(t) - MOP(t) \times L, r_3 \leq 0.5 \\ X_b(t) + MOP(t) \times L, r_3 > 0.5 \end{cases} \quad (6)$$

式中,  $r_3$  为 0~1 之间的随机数;  $L$  的数学模型如式(4)所示。

## 3 诊断模型建立过程

### 3.1 模型介绍

本文算法通过改进 AOA 寻优算法, 具有了增强全局寻优能力和避免陷入局部最优的特点, 同时还提高了收敛速度和精度。此外, 在模型中加入了 TPA 注意力机制, 使得整体模型能够从大量的时序数据信息中选取更重要的特征, 并放大重要特征对诊断结果的影响, 提高诊断准确率和特征提取效率。模型的详细介绍在 3.4 节展示。

### 3.2 改进算数优化算法

#### (1) Tent 混沌映射

AOA 算法虽然参数较少, 结构简单, 适用性广泛, 但它对初始解的依赖性强, 容易陷入局部最优解。为了增加接的多样性, 本文引入了 Tent 混沌序列作为初始解<sup>[16]</sup>。Tent 混沌序列利用其随机性和遍历性, 使得初始解在解空间内分布更均匀, 有助于避免算法陷入局部最优, 提高全局搜索能力。其表达式如下:

$$x_{n+1} = \begin{cases} \frac{x_n}{a}, 0 \leq x_n \leq a \\ \frac{1-x_n}{1-a}, a < x_n < 1 \end{cases} \quad (7)$$

式中,  $a \in (0, 1)$ , 本文取 0.5。Tent 混沌映射 500 次的示意图如图 3 所示。

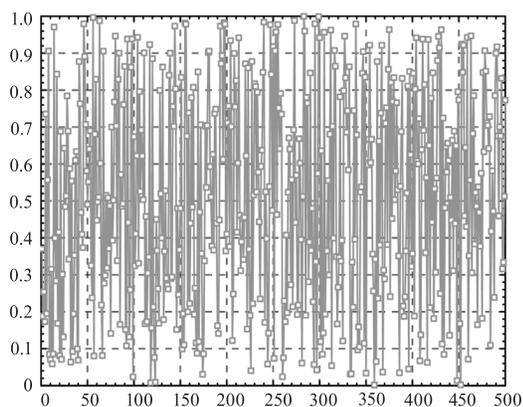


图 3 Tent 混沌映射示意图

Fig. 3 Tent chaos mapping diagram

#### (2) 正弦控制因子策略

为了解决 AOA 在全局搜索能力和局部开发能力不平衡的问题, 本文在 MOA 更新公式中加入了正弦因子控制的非线性惯性权重, 用于动态调节算

法全局搜索与局部搜索的平衡,从而提升算法寻优精度和稳定性<sup>[17]</sup>。新的 MOA 更新公式如下:

$$MOA(t) = Min + t \times \sin \frac{\pi(Max - Min)}{2T} \quad (8)$$

为了验证所提算法的性能,本文依据文献[18]选择了包括高维单峰(F1)、高维多峰(F6、F8)和低维多峰(F10)四个测试函数进行寻优,并绘制了相应的曲线,如图4所示。同时本文将鲸鱼优化算法<sup>[19]</sup>(WOA)、粒子群算法<sup>[20]</sup>(PSO)和基本的算数优化算法作对比,各算法的参数设置相同:种群大小为30,最大迭代次数为500,种群维度为100。由图4可知,IAOA算法相比其他三个算法,具有更快的收敛速度,更强的搜索能力和更高的精度。

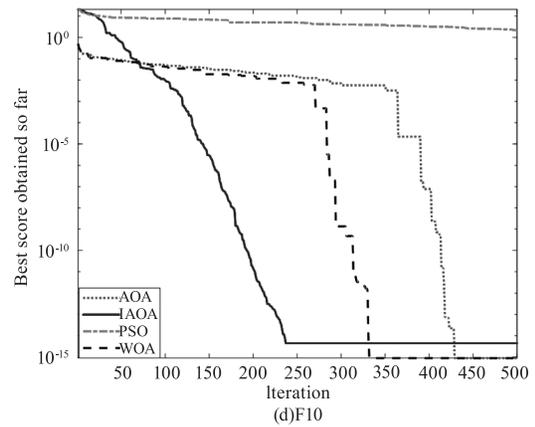
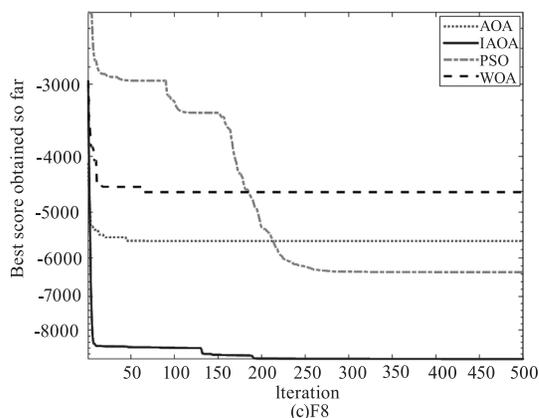
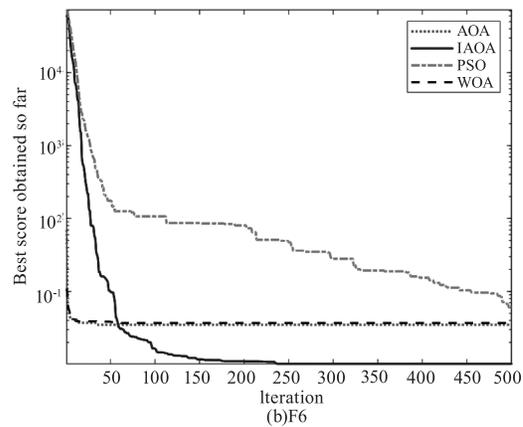
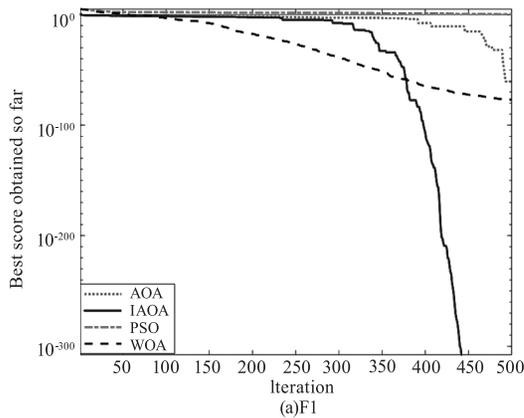


图4 收敛曲线对比图

Fig. 4 Convergence curve comparison Chart

### (3) IA OA-BiLSTM 诊断模型

IA OA-BiLSTM 电路芯片诊断模型建立步骤

如下:

1) 设置种群规模  $N$ , 并初始化 IA OA 基础参数、局部开发精度以及调整搜索过程的控制参数。

2) 利用 Tent 混沌序列随机生成种群, 并以其初始位置表示为超参数  $(\lambda, \xi, G)$  的初始值, 然后计算每个个体适应度值, 并根据适应度值寻找最优种群位置  $X_b$ 。

3) 通过公式(2)来判断种群是处于全局搜索还是局部搜索, 并根据式(3)~(8)更新种群的最新位置。

4) 比较更新后的种群, 选取适应度值最低的种群作为最优位置, 适应度值越低, 个体位置越优, 最后判断是否符合迭代条件。

5) 将迭代结束后产生的最优结果作为 BiLSTM 故障模型的最优超参数组合。

利用 IA OA 算法优化 BiLSTM 模型, 可以找到最优超参数组合。此外, 优化还可以提高训练的效率, 并在训练过程中调整参数以提高模型的泛化能力。

电路芯片故障诊断模型流程图如图5所示。

### 3.3 TPA-BiLSTM 模型构建

针对 BiLSTM 模型在诊断过程由于某些故障特征相似, 导致模型诊断准确率不高的问题, 本文在原有模型中引入 TPA 注意力机制。TPA 可以帮助 BiLSTM 学习特征重要性并分配权重, 有利于深度挖掘提取数据信息中故障特征关系, 从而实现高精度故障诊断。

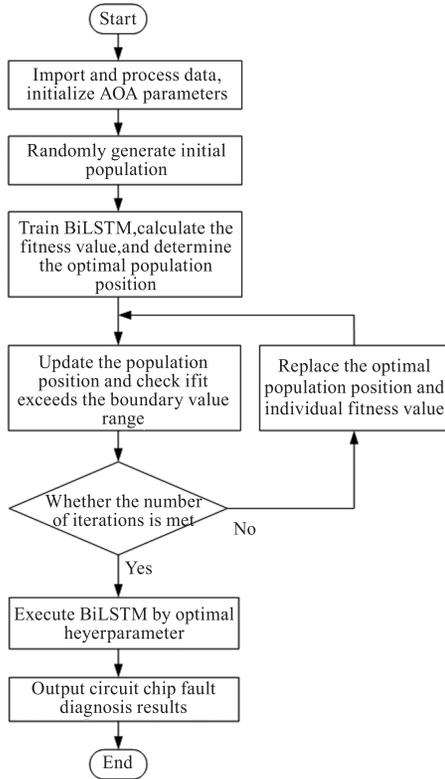


图5 IAOA-BiLSTM 故障诊断模型流程图

Fig. 5 IAOA BiLSTM fault diagnosis model flowchart

TPA-BiLSTM 模型的实现过程如下:

1) 首先输入故障数据, BiLSTM 利用这些数据获得一个隐状态矩阵  $H$ 。

2) 利用 TPA 层的  $k$  个卷积神经网络过滤器对 BiLSTM 得到的隐状态矩阵的每行进行特征提取, 输出如下矩阵:

$$H_{i,j}^C = \sum_{l=1}^w h_{i,(t-w+1+l)} \times C_{j,T-w+1} \quad (9)$$

式中,  $h = \{h_{m,t-w+1}, \dots, h_{m,t}\}$ ;  $w$  是时间序列长度;  $m$  为单一 BiLSTM 单元输出值的维数;  $C = \{C_1, C_2, \dots, C_T\}$  为卷积神经网络滤波器;  $T$  表示注

意力机制的最大长度。

3) 对于要诊断的  $h_{m,t}$ , 将其与  $H^C$  矩阵的每行进行计算, 进而对每行产生一个比例权重  $\alpha_i$ , 利用它们来评估每一个特征的权重, 即每一类故障中, 哪些特征是其主要特征:

$$f(H_i^C, h_{m,t}) = (H_i^C)^T W_a h_{m,t} \quad (10)$$

$$\alpha_i = \text{sigmoid}(f(H_i^C, h_{m,t})) \quad (11)$$

式(10)为分数函数, 用来计算权重,  $H_i^C$  是  $H^C$  的第  $i$  个行向量,  $W_a \in R^{k \times m}$ ; 式(11)为 sigmoid 激活函数, 用于权值归一化。

4) 对每行数据进行加权求和得到  $V_t$ , 其表示了所有行向量对  $h_t$  的综合作用, 即时间序列作用:

$$V_t = \sum_{i=1}^n \alpha_i H_i^C \quad (12)$$

5) 在对  $h_t$  进行诊断时, 在原有的公式上添加时间序列对  $h_t$  的综合影响, 即经过注意力机制获取的第  $t$  时刻隐含层权值:

$$h'_{m,t} = W_h h_{m,t} + W_v V_t \quad (13)$$

式中,  $W_h \in R^{m \times m}$ ,  $W_v \in R^{k \times m}$ 。

6) 最后, 在训练中不断地调整权重的优化, 进而提高故障诊断精度, 并输出诊断结果:

$$HI_i = W_{h'} h'_{m,t} \quad (14)$$

式中,  $W_{h'} \in R^{k \times m}$ 。

### 3.4 故障诊断模型构建

基于上述三节所述, 本文提出的故障诊断模型包括以下几个部分: 提取温度数据部分、输入层、IAOA 优化 BiLSTM 层、TPA 注意力层、全连接层和 Softmax 输出层。

基于 TPA 的 IA OA-BiLSTM 电路芯片故障诊断模型结构如图 6 所示。

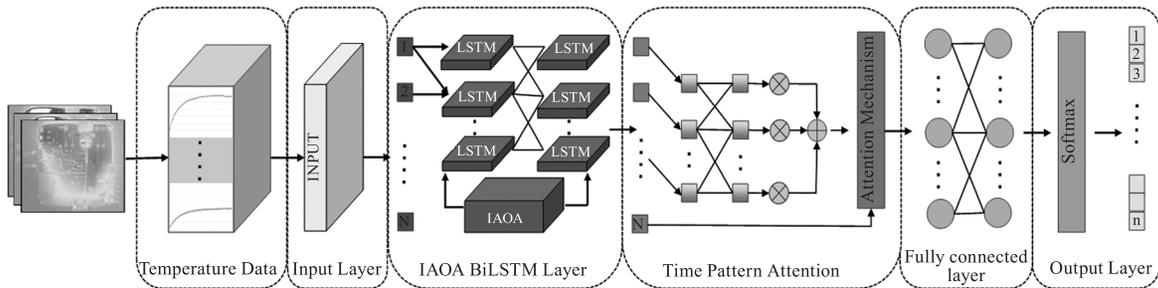


图6 基于 TPA 的 IA OA-BiLSTM 电路芯片故障诊断模型结构图

Fig. 6 Structure diagram of IA OA BiLSTM circuit chip fault diagnosis model based on TPA

步骤 1, 采集和预处理数据。首先利用红外设备采集电路芯片故障数据, 对数据进行归一化处理

并进行数据划分和添加属性标签。

步骤 2, 优化故障诊断模型。通过 AOA 进行全

局搜索和局部搜索,以寻找 BiLSTM 网络最优超参数组合。

步骤 3,提取故障特征。将预处理好的故障数据输入到优化后 BiLSTM 中,BiLSTM 将训练集或测试集中的时序故障数据信息分别送入到不同的 LSTM 网络中,再将双向数据信息拼接后得到的隐状态向量  $h_{t-w}, \dots, h_{t-1}, h_t$  输送到注意力层。

步骤 4,选取重要特征。TPA 注意力层通过隐藏状态  $V_t$  与隐状态向量进行线性计算,给重要特征信息分配较大的权重比例,并输出到下一层。

步骤 5,整合特征向量并分类。全连接层整合 TPA 层输出的特征向量;Softmax 层根据特征向量输出故障类的概率,最后通过输出层输出故障诊断结果。

#### 4 模拟电路芯片故障诊断实验及分析

##### 4.1 数据采集以及实验设备

实验采用英福泰克 (InfraTec) ImageIR <sup>®</sup> 5300 系列红外热像仪,热灵敏度为 0.015 K (30 °C),分辨率为 320 × 256。计算机配置如下:windows11 系统,CPU 为 i5 - 12400F, GPU 为 NVIDIA GeForce GTX 1650, MATLAB2020a, 16 GB 内存。实验在实验室环境下进行,室温受季节变化影响。

实验电路为航空某电源电路板中的 0 ~ 30 V 可调直流稳压电源电路,该电路采用模拟电路集成芯片,可以调节输出电压。实验以 10 V、20 V、30 V 三种输出模式为基准,分别在空载、1020 Ω、330 kΩ 负载下模拟不同的工况。图 7 展示了实验中电路芯片在发热状态下的灰度图像。

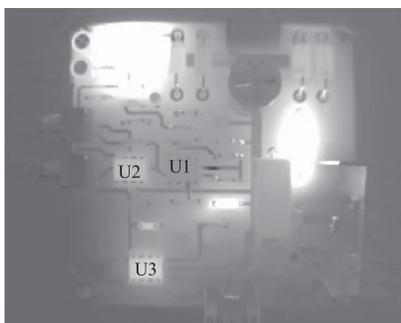


图 7 实验电路灰度图

Fig. 7 Experimental circuit grayscale image

##### 4.2 实验设置

###### (1) 故障设置

芯片故障主要包括以下故障:在电路开关瞬间产生的瞬时高压或瞬时电流时,可能会导致超出芯

片的额定供电电压或电流最高承受值,导致芯片管脚短路或者断路。另外,还静电也能导致芯片短路,而外力挤压、振荡以及由于焊接操作不当等原因而导致的芯片管脚断路故障。为了模拟这些芯片的故障模式,本实验设置了 27 种故障,涵盖了 U1、U2 和 U3 芯片,详情见表 1 所示。

表 1 电路芯片故障模式对照表

Tab. 1 Comparison table of circuit chip fault modes

| 故障模式      | 故障原因    |
|-----------|---------|
| F1        | 正常      |
| F2 ~ F6   | U1 芯片断路 |
| F7 ~ F13  | U2 芯片断路 |
| F14 ~ F18 | U3 芯片断路 |
| F19 ~ F21 | U1 芯片短路 |
| F22 ~ F24 | U2 芯片短路 |
| F25 ~ F27 | U3 芯片短路 |

实验设置每种故障采集 5 组,每组包含 300 个数据。为了消除季节变化对温度的影响,分别采集芯片最高温度和最低温度并作差,构建数据集如表 2 所示。

表 2 数据集构建表

Tab. 2 Dataset construction table

|       | 数据集 1                                | 数据集 2                           |
|-------|--------------------------------------|---------------------------------|
| 工况说明  | 负载:空载,1020 Ω,330 kΩ;<br>电压:10 V,20 V | 负载:空载,1020 Ω、<br>330 kΩ;电压:30 V |
| 数据量/组 | 训练集 810                              | 测试集 405                         |

###### (2) 超参数设置

BiLSTM 故障诊断模型中涉及多个超参数,其中对模型影响最大的超参数主要是最佳隐藏层节点数  $G$ 、最佳初始学习率  $\xi$ 、最佳 L2 正则化系数  $\lambda$ 。因此,在模型超参数寻优中设定了如表 3 所示的范围。

表 3 超参数寻优范围

Tab. 3 Optimization range of hyperparameter

| 超参数                   | 寻优范围                       |
|-----------------------|----------------------------|
| 最佳隐藏层节点数 $G$          | [10 ~ 500]                 |
| 最佳初始学习率 $\xi$         | [0.0001 ~ 0.1]             |
| 最佳 L2 正则化系数 $\lambda$ | [ $10^{-10}$ ~ $10^{-2}$ ] |

###### (3) 模型参数设置

首先,加载数据集 1 作为训练集,数据集 2 作为测试集。然后,为了消除奇异样本数据产生的不良影响,对数据集进行统一的归一化处理。接下来,按照表 3 设定 IAOA 初始参数范围,得到最佳超参数组合:  $G, \xi, \lambda$ , 并将其输入到诊断模型中;采用 Adam 自适应优化方法来更新诊断模型其他参数,并使用动态学习率来训练网络模型,初始学习率为优化后的最优参数。训练过程设置 100 次迭代,当经过 80 次迭代后,学习率为初始学习率 0.5,其作用是保持模型平稳运行并加快收敛速度;训练过程中使用 L2 正则化系数防止过拟合。设置 TPA 机制时间步长为 15。具体的模型参数设置见表 4 所示。

表 4 故障诊断模型参数表

Table 4 Parameter table of fault diagnosis model

| 模型     | 主要参数                  | 参数名称               |
|--------|-----------------------|--------------------|
| AOA    | 种群数量                  | 5                  |
|        | 迭代次数                  | 30                 |
|        | 优化参数个数                | 3                  |
|        | 适应度值                  | 1.71               |
| BiLSTM | 最佳隐藏层节点数 $G$          | 300                |
|        | 最佳初始学习率 $\xi$         | 0.002              |
|        | 最佳 L2 正则化系数 $\lambda$ | $1 \times 10^{-8}$ |
| TPA    | 时间步长                  | 15                 |
| FC     | 全连接隐藏层节点              | 27                 |

#### 4.3 电路芯片故障诊断实验

在 IAOA 算法寻优结束后,将得到的最优超参数组合输入到 TPA-BiLSTM 模型中。为了验证模型的故障诊断性能,本文将数据集 1 作为训练集,数据集 2 作为测试集,并给出了测试集的分类结果图和训练曲线图,如图 8,图 9。图 8 中横轴表示样本数量,纵轴表示样本类别。图 9 中实线为损失曲线,虚线为训练准确率曲线。

由图 8 可以看出,模型在数据集 2 上的故障诊断准确率达 98.27%,基本能够识别出每个故障状态类别。因此,本文提出的模型能够准确的识别故障类型,并具备良好的故障诊断效果。

从图 9 可以观察到,随着迭代训练的进行,模型准确率逐渐提高且损失率逐渐下降,在大约 40 次迭代后,模型在数据集 2 上的准确率达到平稳状态。

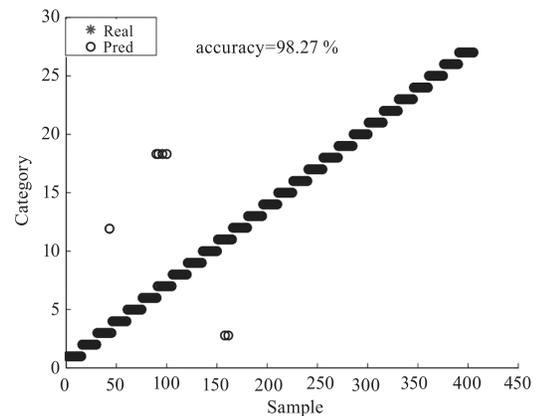


图 8 数据集 1 诊断结果图

Fig. 8 Dataset 1 diagnostic results chart

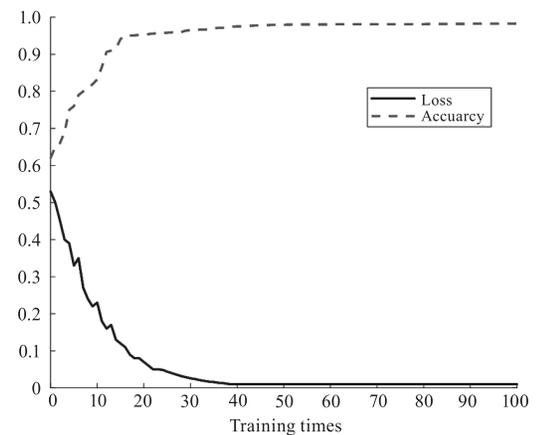


图 9 模型训练曲线图

Fig. 9 Model training curve

为了更直观了解电路芯片每个故障状态的识别精度,图 10 为故障诊断的混淆矩阵结果图,从图中可以观察到,大多数类别的识别结果达到了 100%,这也进一步说明了本文模型对电路芯片故障具有良好的诊断性能和可靠性。

为了进一步验证模型的有效性以及改进优化算法在故障诊断过程中的重要作用,本文将改进算法与其他优化方法进行对比,包括鲸鱼优化算法(WOA)、粒子群优化算法(PSO)和基础算数优化算法(AOA)。通过在故障数据集 2 上反复对比实验验证,得到了不同优化算法的准确结果,如图 11 所示,从图中可以明显看出,尽管 AOA 算法能够达到 93.14% 的准确率,但其收敛速度较慢。此外,WOA 和 PSO 算法准确率虽然也能完成基本的故障诊断,但是容易陷入局部最优,收敛速度较慢,影响了在超参数寻优方面的表现。而本文 IAOA 算法无论在收敛速度以及准确度方面都具有良好的诊断效果。

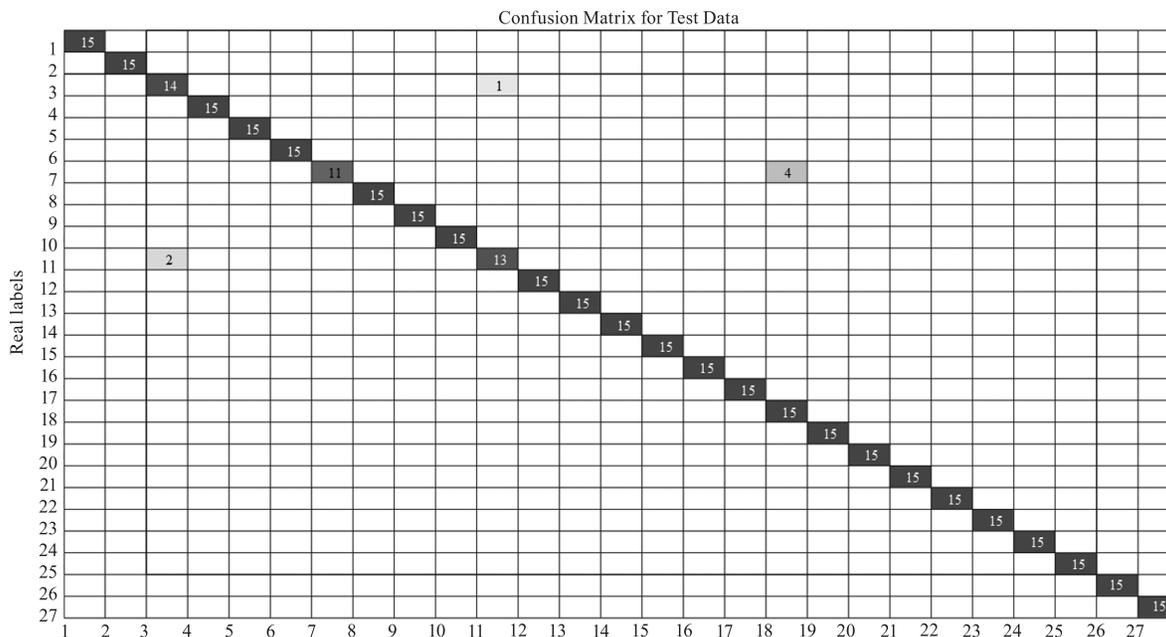


图 10 混淆矩阵结果图

Fig. 10 Results of confusion matrix

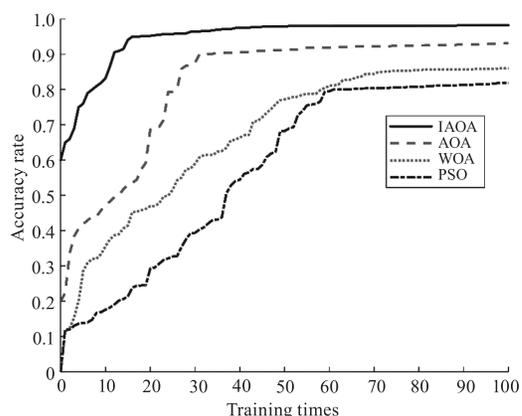


图 11 不同优化算法下的准确率

Fig. 11 Accuracy under different optimization algorithms

#### 4.4 诊断模型评价指标及模型消融实验

为了更好地评估故障诊断模型的诊断效果,本文引入以下的评判标准:

(1) 准确率(Accuracy)

$$Accuracy = \frac{TP}{TP + FP + FN} \quad (15)$$

式中,  $TP$  为正确诊断故障次数;  $FN$  为误诊为其他类的次数;  $FP$  表示为漏诊为本类的次数。准确率能够很好地衡量诊断结果的正确性。

(2) 查全率(Rec)

$$Recall = \frac{TP}{TP + FN} \quad (16)$$

其实际含义是诊断正确的故障类型在所有诊断结果中的比例。查全率越低,说明错误诊断越多;反

之则是更低的误诊。

(3) 查准率(Precision)

$$Precision = \frac{TP}{TP + FP} \quad (17)$$

查准率是诊断某类故障正确的次数在所有此类诊断结果中的比例。查准率可以准确地反映模型诊断的精确性。

(4) 宏 F1 (Macro - F1 Score)

$$\begin{cases} F1_i = 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i} \\ Macro - F1 = \frac{1}{n} \sum_{i=1}^n F1_i \end{cases} \quad (18)$$

F1 Score 表示为精确率和召回率的平均值,是一种评价多分类指标的方法,其值在  $[0,1]$  之间,且值越大代表模型的分类效果越好。

本文为了验证模型的鲁棒性和优势,结合评价指标对模型结构进行了消融实验,其结果对比如表 5 所示。

表 5 结果对比表

Tab. 5 Comparison of results

| Model        | Acc/% | Pre/%   | Rec/% | M - F1/% |
|--------------|-------|---------|-------|----------|
| BiLSTM       | 82.61 | 81.46 % | 80.76 | 81.1     |
| AOA-BiLSTM   | 91.45 | 92.38   | 91.24 | 91.8     |
| IA OA-BiLSTM | 95.76 | 94.65   | 95.89 | 95.27    |
| 本文算法         | 98.27 | 98.49   | 98.27 | 98.38    |

通过表 5 的实验结果可以发现, BiLSTM 模型虽然能完成诊断目的, 但其诊断效果不佳, 无法满足实际的诊断要求; 加入 AOA 优化算法后的诊断模型在诊断准确率、查准率、查全率以及 F1 评价指标上都有了显著的提升, 且能够诊断出大部分故障, 但仍有改进的空间。另外, 引入改进后的优化算法后, 诊断模型的准确率上提高了 4.3%, 这也证明了改进优化算法的必要性。最后, 在模型中加入 TPA 注意力机制后, 模型的准确率以及其他评价指标进一步提高, 并且还提高了模型选取重要特征的效率。

综上所述, 本文所提出的故障诊断模型在电路芯片的故障诊断中表现出较高的诊断准确率和鲁棒稳定性。

## 5 结 论

本文采用基于 TPA 的 IAQA-BiLSTM 故障诊断模型进行电路芯片故障诊断。该方法具有以下特点:

1) 利用红外温度数据检测芯片故障状态和诊断芯片故障类型, 具有及时发现芯片故障和实现芯片故障定位等优点。

2) 利用 IAQA 优化 BiLSTM 的超参数, 既避免了人工利用经验设置超参数, 又避免了手动提取和选择特征的过程, 从而节省时间并减少人工干预。

3) 模型加入了注意力机制, 保证了重要特征信息提取的全面性, 提高了模型诊断精度和特征提取效率。

综上所述, 实验结果表明, 本文所述故障诊断模型在电路芯片故障诊断中具有良好的诊断效果。与传统方法相比, 降低了人工参与度, 提高了诊断精度和效率。未来, 将针对更多类型电路芯片诊断开展研究, 并结合理论与实践, 验证该方法的优越性和可行性。

## 参考文献:

- [1] Hao Jianxin, Jia Chunyu. Research on fault mode diagnosis of airborne circuit board based on infrared heat map [J]. *Infrared Technology*, 2019, 41(3): 273 - 27. (in Chinese)  
郝建新, 贾春宇. 基于红外热图的机载电路板故障模式诊断研究[J]. *红外技术*, 2019, 41(3): 273 - 278.
- [2] Wang Li, Liu Ziqi. Fault diagnosis of analog circuits using WPA-IGA-BP neural networks [J]. *Systems Engineering and Electronic Technology*, 2021, 43(4): 1133 - 1143. (in Chinese)  
王力, 刘子奇. WPA-IGA-BP 神经网络的模拟电路故障诊断 [J]. *系统工程与电子技术*, 2021, 43(4): 1133 - 1143.
- [3] Hao Jianxin, Wang Li. Research on circuit board fault diagnosis based on infrared temperature sequence [J]. *Infrared and Laser Engineering*, 2023, 52(4): 59 - 70. (in Chinese)  
郝建新, 王力. 基于红外温度序列的电路板故障诊断研究 [J]. *红外与激光工程*, 2023, 52(4): 59 - 70.
- [4] Dong Z, Chen L. Image registration in PCB fault detection based on infrared thermal imaging [C]//2019 Chinese Control Conference (CCC). IEEE, 2019: 4819 - 4823.
- [5] El Belghiti Alaoui N, Tounsi P, Boyer A, et al. Detecting PCB assembly defects using infrared thermal signatures [C]//26th International Conference Mixed Design of Integrated Circuits and System (2019 MIXDES), 2019: 345.
- [6] Li Guanghong, Lei Jian. Research on key technologies of PCB infrared thermal image detection based on information fusion [J]. *Infrared Technology*, 2017, 39(9): 829 - 834. (in Chinese)  
李广宏, 雷建. 基于信息融合的 PCB 红外热像检测关键技术研究 [J]. *红外技术*, 2017, 39(9): 829 - 834.
- [7] Lv Ang, Chen Yi, Fang Jinyong, et al. Fault detection of circuit board mounted devices based on infrared thermal imaging [J]. *Laser & Infrared*, 2018, 48(5): 579 - 584. (in Chinese)  
吕昂, 陈怡, 方晋甬, 等. 基于红外热成像的电路板载器件故障检测 [J]. *激光与红外*, 2018, 48(5): 579 - 584.
- [8] Wang Li, Xie Xiaohuai, Zhang Yichi. ISSA-BP neural network airborne circuit board chip fault diagnosis based on infrared images [J]. *Infrared Technology*, 2023, 45(3): 241 - 248. (in Chinese)  
王力, 谢晓怀, 张亦弛. 基于红外图像的 ISSA-BP 神经网络机载电路板芯片故障诊断 [J]. *红外技术*, 2023, 45(3): 241 - 248.
- [9] Jiang Ye, Huang Yifan, Xiong Meiming, et al. Research on solder joint defect detection of PCBA onboard DDR chip [J]. *Journal of Instrumentation*, 2023, 44(2): 129 - 137. (in Chinese)  
姜也, 黄一凡, 熊美明等. PCBA 板载 DDR 芯片焊点缺陷检测研究 [J]. *仪器仪表学报*, 2023, 44(2): 129 - 137.
- [10] Wang Yang, Yang Li. Infrared intelligent status monitoring and fault diagnosis of rotating machinery [J]. *Optical Precision Engineering*, 2022, 30(16): 1905 - 1914. (in Chinese)  
王洋, 杨立. 旋转机械红外智能状态监测与故障诊断 [J]. *光学精密工程*, 2022, 30(16): 1905 - 1914.

- [11] Mehra R. Thermal imaging-based fault diagnosis of electronics circuit boards[C]//Advances in Energy Technology: Select Proceedings of EMSME 2020. Springer Singapore, 2022; 111 – 121.
- [12] Yu Ping, Zhao Kang, Cao Jie Rolling bearing fault diagnosis based on optimized A-BiLSTM[J/OL]. Journal of Jilin University: Engineering Edition; 1 – 10[2023 05 17]. (in Chinese)  
余萍, 赵康, 曹洁. 基于优化 A-BiLSTM 的滚动轴承故障诊断[J/OL]. 吉林大学学报: 工学版; 1 – 10[2023 – 05 – 17].
- [13] Nacer S M, Nadia B, Abdelghani R, et al. A novel method for bearing fault diagnosis based on BiLSTM neural networks[J]. The International Journal of Advanced Manufacturing Technology, 2023; 1 – 16.
- [14] SHIH S Y, SUN F K, LEE H. Temporal pattern attention for multivariate time series forecasting [J]. Machine Learning, 2019, 108(8): 1421 – 1441.
- [15] Abusligah L, Diabat A, Mirjalili S, et al. The arithmetic optimization algorithm[J]. Computer Methods in Applied Mechanics and Engineering, 2021, 376: 113609.
- [16] Zhang Na, Zhao Zedan, Bao Xiao'an, et al. Based on an improved tent chaotic universal gravity search algorithm [J]. Control and Decision Making, 2020, 35(4): 893 – 900. (in Chinese)  
张娜, 赵泽丹, 包晓安等. 基于改进的 Tent 混沌万有引力搜索算法[J]. 控制与决策, 2020, 35(4): 893 – 900.
- [17] Xu Chenhua, Luo Zhuguang, Wu Guanrong, et al. Grey wolf optimization algorithm based on sine factor and quantum local search[J]. Computer Engineering and Applications, 2021, 57(24): 83 – 89. (in Chinese)  
徐辰华, 骆珠光, 吴冠宏等. 基于正弦因子和量子局部搜索的灰狼优化算法[J]. 计算机工程与应用, 2021, 57(24): 83 – 89.
- [18] Pan Ke, Zhang Wei, Wang Yagang. Special forces algorithm: a new metaheuristic algorithm[J]. Control and Decision Making, 2022, 37(10): 2497 – 2504. (in Chinese)  
潘科, 张伟, 王亚刚. 特种部队算法: 一种新的元启发式算法[J]. 控制与决策, 2022, 37(10): 2497 – 2504.
- [19] Zheng Zhi, Zhang Huaqin, Pan Yue. Rolling bearing fault diagnosis based on improved whale algorithm optimized LSTM[J]. Vibration and Shock, 2021, 40(7): 274 – 280. (in Chinese)  
郑直, 张华钦, 潘月. 基于改进鲸鱼算法优化 LSTM 的滚动轴承故障诊断[J]. 振动与冲击, 2021, 40(7): 274 – 280.
- [20] Liu Kezhen, Gou Jiachi, Luo Zhao, et al. Prediction method of dissolved gas concentration in transformer oil based on particle swarm optimization short and long term memory network model [J]. Grid Technology, 2020, 44(7): 2778 – 2785. (in Chinese)  
刘可真, 苟家冀, 骆钊, 等. 基于粒子群优化 – 长短期记忆网络模型的变压器油中溶解气体浓度预测方法[J]. 电网技术, 2020, 44(7): 2778 – 2785.