

DOI: 10.19650/j.cnki.cjsi.J2210230

基于自注意力机制的深度学习模拟电路故障诊断*

杨东儒¹, 魏建文¹, 林雄威², 刘明², 鲁圣国¹

(1. 广东工业大学集成电路学院 广州 510006; 2. 深圳信息职业技术学院微电子学院 深圳 518000)

摘要:模拟电路是集成电路中的重要组成部分,基于深度学习技术对模拟电路发生的故障进行检测,并精准识别故障的类型是当前集成电路测试领域的研究热点。针对模拟集成电路故障检测存在困难的问题,利用人工智能在图像识别领域、语音分类领域的先进技术,提出了基于自注意力机制检测 Sallen-Key 型低通滤波电路故障的深度学习模拟电路故障检测方案,将输出信号采样成音频信号,并将其输入到自注意力变换网络的音频分类模型中进行训练、测试和优化。结果表明,通过自注意力变换网络音频分类在 9 种不同的故障类型诊断中,平均准确率达 93.1%,最高准确率达 98.1%。该模型收敛速度更快,具有较强的模拟电路故障检测能力。

关键词: 集成电路测试;故障检测;深度学习;频谱图;自注意力变换网络

中图分类号: TH407 TN37 **文献标识码:** A **国家标准学科分类代码:** 510.10 520.20

A fault diagnosis algorithm for analog circuits based on self-attention mechanism deep learning

Yang Dongru¹, Wei Jianwen¹, Lin Xiongwei², Liu Ming², Lu Shengguo¹

(1. School of Integrated Circuits, Guangdong University of Technology, Guangzhou 510006, China;

2. School of Microelectronics, Shenzhen Institute of Information Technology, Shenzhen 518000, China)

Abstract: Analog circuit is an essential part of the integrated circuit. One of the current research hotspots in integrated circuit testing is the detection of faults occurring in analog circuits and the accurate identification of fault types based on deep learning techniques. To address the difficulties in fault detection of analog integrated circuits, the advanced achievements of artificial intelligence in the field of image recognition and speech classification is referenced and an analog circuit fault detection idea based on a deep learning algorithm of self-attention mechanism is proposed, which can be used to detect faults in Sallen-Key low-pass filter circuits. The output signal is sampled into an audio signal and fed into an audio classification model based on a self-attentive transform network for training, testing, and optimization. The results show that fault detection based on the self-attentive mechanism audio classification has an average accuracy of 93.1% and a maximum accuracy of 98.1%. Nine different fault types can be detected. The model converges fast and can detect faults in analog circuits, which thoroughly verifies the feasibility of the proposed idea.

Keywords: integrated circuits testing; fault detection; deep learning; spectrogram; self-attention transformer network

0 引言

近年来,随着电子技术和电子消费市场的快速发展,集成电路的集成度和复杂度也变得越来越高。模拟集成电路作为电子产业中的重要组成部分,在制造过程中往

往存在难以检测的隐患,导致使用后期造成不可逆转的损失。因此,及时诊断模拟电路中是否发生故障以及有效诊断故障的类型有助于优化模拟电路的应用场景,提高成品水准。

传统的模拟电路检测方法主要有故障字典法、故障验证法^[1-2]。这两种方法都十分依赖已有的数据来推断

收稿日期:2022-07-30 Received Date: 2022-07-30

* 基金项目:东莞市核心技术攻关前沿项目(2019622101006)、深圳市科技计划项目(JCYJ20180307123857045)、深圳信息职业技术学院科研项目(SZJIT2022KJ019)资助

发生故障的元器件的概率,再用已知的数据库来进行验证。但随着现代集成电路的规模越来越大、集成度越来越高,传统的方法已经很难同时满足快速的检测效率和优良的检测效果。

随着人工智能技术的发展,机器学习算法如支持向量机(support vector machine, SVM)、循环神经网络(recurrent neural network, RNN)和长短时记忆网络(long short-term memory, LSTM)也被应用到模拟电路故障诊断中。Zhang等^[3]研究了SVM在模拟电路故障诊断中的应用,并成功区分出4种故障种类。Yu等^[4]研究了基于萤火虫算法、帐篷混沌映射与极限学习机融合的新型故障检测和诊断的方法(firefly algorithm tent chaotic map and extreme learning machine, FA-TM-ELM),在故障诊断中具备了良好的泛化能力。He等^[5]则通过主成分分析法分析数据以减小输入到神经网络(neural networks, NN)中的维数,并同步基于粒子群优化和径向基函数(radial basis function, RBF)的神经网络模型来实现故障检测。Liu等^[6]基于RBF做了进一步的改进,结合神经网络以及引导聚集算法(bootstrap aggregating, Bagging)实现了对模拟电路故障的有效分类。Hu等^[7]使用多小波变换(multi wavelet)实现了模拟电路故障的检测。张朝龙等^[8]则基于深度置信网络实现了模拟电路早期故障的诊断方法,诊断正确率最高达到了98.13%。文献[9-10]提出了基于图像识别的模拟电路故障检测的方法,将输出信号的功率谱密度(power spectrum density, PSD)转换成二维图像输入到深度卷积神经网络(deep convolutional neural networks, DCNN)中,实现了图像分类从而达到故障检测的目的。该方案在Sallen-Key电路的单一故障检测中实现了高达99.8%的准确率。

尽管传统的机器学习算法在模拟电路故障检测中获得了较佳的效果,但是,传统的算法存在一定的局限性。例如,传统机器学习算法如SVM设计的初衷是实现二分类,适用于小样本学习的情景,在对于模拟电路故障检测的多分类、海量样本时效果较为一般^[11-12]。典型的深度学习算法如CNN更适合用于二维数据而非序列数据^[13],RNN、LSTM无法有效捕捉长时序数据中各元素之间的关系等问题^[14-16]。因此,Vaswani等^[17]提出了自注意力变换网络模型(self-attention transformer)。基于该模型,Dosovitskiy等^[18]在图像识别方案、Gong等^[19]在音频分类方案中获得了的较佳的效果。由于模拟电路输出信号作为时间序列信号,在模拟电路故障诊断中同样可以使用自注意力变换网络模型。

基于图像识别的方案已经在模拟电路故障诊断中达到了较为优秀的表现性能^[20],但所使用的典型深度学习方法如CNN等,对于不同模拟电路往往需要高昂的训练成本。自注意力变换网络能够预先在大规模数据上进行

预训练,当其应用于下游任务时,可以更快地收敛得到诊断结果,有效降低训练成本。

本文采用基于音频分类深度学习的方法解决模拟电路故障检测问题。即将模拟电路的输出信号采样成音频信号,从而将模拟信号识别问题转换为音频分类问题;从而可以直接充分利用深度学习在音频分类领域的成果提高模拟电路的故障监测能力。基于此思路,本文提出了提出了基于自注意力机制检测Sallen-Key型低通滤波电路故障的深度学习模拟电路故障检测方案,训练模型的成本更低,能够有效识别9种故障并做出分类,故障检测平均准确率达93.1%,最高准确率达98.1%。

1 基于自注意力机制的深度学习模型设计

目前,传统的神经网络模型在处理序列模型时存在明显不足。如RNN、LSTM等存在并行化差,无法很好地捕捉长时序的特征;CNN则更适用于二维局部数据之间的相互关联^[13-16]。针对上述问题,Vaswani等^[17]模拟人类在观察对象时对局部特定内容的重点关注,提出了自注意力机制,通过将模型的注意力专注于对象信息的不同位置来提升其获取信息的能力。

随着自注意力机制在自然语言处理领域中的大放异彩^[21],许多研究人员也将其进一步应用到不同的领域^[22],如图像识别等,并取得了非常好的结果^[18]。Gong等^[19]提出了音频频谱图变换网络(audio spectrogram transformer, AST),首次将纯自注意力模型应用到了音频分类中,并取得了媲美SOTA模型的效果。音频频谱图变换网络首先将音频映射成频谱图,然后将基于传统自然图像数据集ImageNet^[23]预训练得到的高效数据图像转换网络(data-efficient image transformers, DeiT)^[24]迁移到频谱图分类上,从而实现音频分类。由于模拟电路输出信号作为时序信号^[25],在采样成音频信号后同样可以通过音频分类实现模拟电路的故障检测。

1.1 自注意力机制模型结构

以AST模型为基础,通过修改若干超参数以及部分网络结构,构造出模拟电路故障检测网络模型。所做出的改进主要如下:

- 1) 加入SoftMax层,以便实现多分类任务。
- 2) 引入了Dropout机制,防止模型出现过拟合。
- 3) 引入了冻结参数机制,实现让网络在训练的时候冻结无关参数,加快了模型的收敛速度。
- 4) 修改了损失函数。

如图1所示,为提出的模型结构。首先将从模拟电路中采集到的输出信号采样成音频信号,然后将音频信号映射成频谱图作为模型的输入。有关数据预处理部分

将在下面详细提到。频谱图输入到模型中之后,会经过一个大小为 16×16 ,步长为10的分割处理,得到一个

序列作为下一步的输入。在下一步中,通过线形层将输入的序列展平成1维的序列。

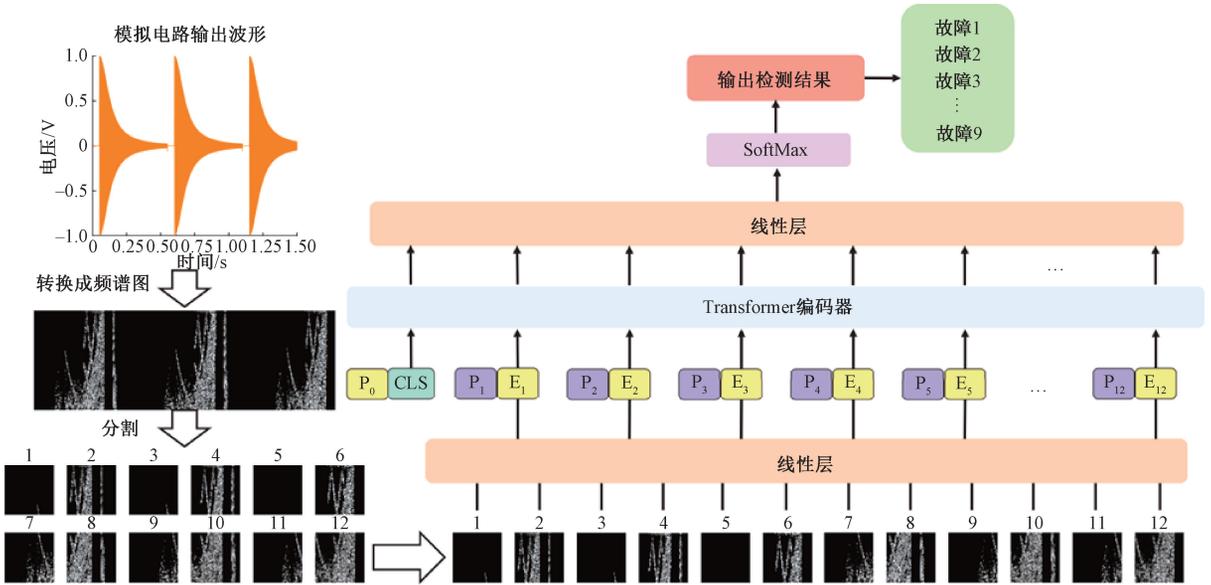


图1 基于自注意力机制的模拟电路故障诊断模型结构

Fig. 1 Model architecture of analog circuit fault diagnosis based on self-attention mechanism

由于自注意力变换网络没有直接捕获输入顺序信息,且输入的序列也非时间顺序排列。因此,需要额外添加位置编码,使得模型可以从音频频谱图中捕获到空间时间信息。此外,还需要加入类别编码 CLS 以及其对应的位置编码到序列的头部。

典型的自注意力变换网络由编码器和解码器组成^[17,19]。模拟电路故障中使用的是具有12头自注意力机制的编码器,通过 SoftMax 激活函数得到分类的结果。SoftMax 函数的数学表达式为:

$$f(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (1)$$

1.2 自注意力机制检测算法

首先将采集到的数据集进行预处理,以70%、20%和10%划分成训练集、验证集和测试集,分别进行数据增强。加载预训练的自注意力变换网络模型,输入数据进行训练和验证,并计算损失函数。判断损失函数是否收敛,如果未收敛则继续训练和验证;收敛则保存模型。加载已训练好的模型,使用测试集对其性能进行测试,最终得到用于检测模拟电路故障的模型。损失函数的数学表达式如下:

$$Loss = \{l_1, \dots, l_N\} \quad (2)$$

$$l_n = - \left[y_n \cdot \log \left(\frac{1}{1 + e^{-x}} \right) + (1 - y_n) \cdot \log \left(1 - \frac{1}{1 + e^{-x}} \right) \right] \quad (3)$$

2 模拟电路故障数据集

为检测本文提出的模拟电路故障检测算法的有效性,选择 Sallen-Key 低通滤波器作为测试对象。Sallen-Key 低通滤波器是由 Sallen 以及 Key 提出的一种基于单个运算放大器、电阻、电容组成的电路,其原理图如图2所示。图2中,电阻 R_1 、 R_2 的值均为10 k Ω ,电容 C_1 、 C_2 的值均为1 nF,运算放大器采用了3554AM型,由 ± 12 V双电压供电。

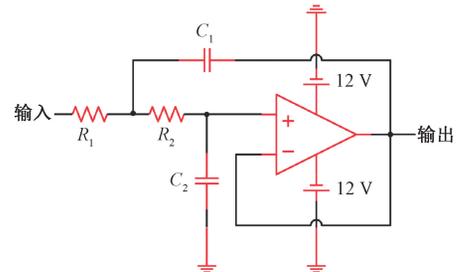


图2 Sallen-Key 低通滤波电路

Fig. 2 Sallen-Key low-pass filter circuit

2.1 数据集生成

本文将 C_1 、 C_2 、 R_1 以及 R_2 作为故障元器件,其中每个故障元器件都设置了5%的冗余度。元器件的故障值范围为50%,即大于或者小于其标准值的50%即为出现

故障,以 $X \uparrow$ 和 $X \downarrow$ 代表大于标准值 50% 和小于标准值 50%,其中 X 为所出故障的元器件。表 1 中为故障元器件的标准值、故障值以及对应的故障代码。

本文基于 PSpice 进行电路仿真得到相应的数据集。其具体参数设置如下:

1) 输入信号 INPUT 为频率从 0 Hz 逐步增加至 100 000 Hz,振幅为 1 V,周期为 0.5 s 啁啾信号。

2) C_1 和 C_2 的标准值均设置为 1 nF,故障值均设置为 0.5 和 1.5 nF。 R_1 、 R_2 的标准值均设置为 10 k Ω ,故障值设置为 5 和 15 k Ω 。

3) 通过蒙特卡洛方法对输出节点 OUTPUT 进行信号采集,其中蒙特卡洛方法的容差值设置为高斯分布的 5%,采样时长为 1.5 s。

最终得到的数据为每种类型均有 100 条输出波形数据。所采集到的数据集如表 1、2 所示。

表 1 元器件故障类型及故障代码

Table 1 Component fault types and fault codes

故障代码	故障类型	标准值	故障值
0	$C_1 \uparrow$	1 nF	1.5 nF
1	$C_1 \downarrow$	1 nF	0.5 nF
2	$C_2 \uparrow$	1 nF	1.5 nF
3	$C_2 \downarrow$	1 nF	0.5 nF
4	正常	—	—
5	$R_1 \uparrow$	10 k Ω	15 k Ω
6	$R_1 \downarrow$	10 k Ω	5 k Ω
7	$R_2 \uparrow$	10 k Ω	15 k Ω
8	$R_2 \downarrow$	10 k Ω	5 k Ω

表 2 模拟电路故障数据集

Table 2 Analog circuit fault dataset

标签	故障类型	长度/s	样本数量
C_{1H}	$C_1 \uparrow$	1.5	100
C_{1L}	$C_1 \downarrow$	1.5	100
C_{2H}	$C_2 \uparrow$	1.5	100
C_{2L}	$C_2 \downarrow$	1.5	100
正常	正常	1.5	100
R_{1H}	$R_1 \uparrow$	1.5	100
R_{1L}	$R_1 \downarrow$	1.5	100
R_{2H}	$R_2 \uparrow$	1.5	100
R_{2L}	$R_2 \downarrow$	1.5	100

2.2 数据预处理

为了更好地训练模型以及降低计算量,需要对所采集到的数据进行数据预处理。

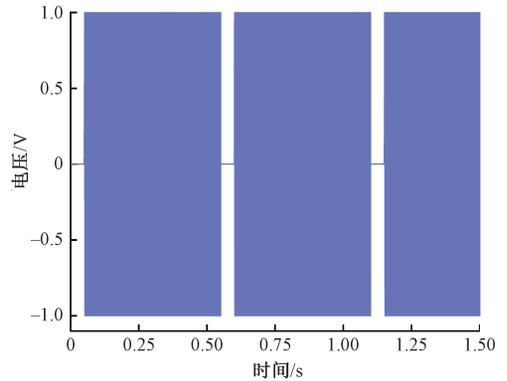
1) 标准化处理。为了使得所采集到的数据进一步标准化以及可以更好地训练神经网络模型,对每个样本的数据进行标准化处理。本文采用的标准化处理方式为 min-max 标准化。其数学表达式为:

$$X = \{x_i\} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

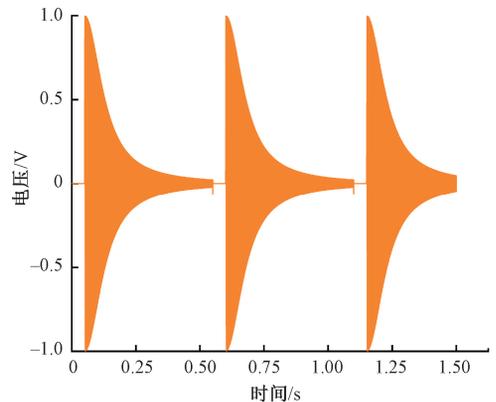
2) 频谱图转换。首先将输出信号重采样成音频信号,然后对每一条音频信号都采用了 128 维对数梅尔滤波器组进行映射成频谱图,其中每 10 ms 进行一次该操作。为了防止频谱泄露,对于每 10 ms 的片段采取了长度为 25 ms 的汉明窗进行加窗处理。

3) 数据集划分。将经过上述处理后的 9 种类型各 100 个数据样本随机划分为训练集、验证集和测试集,比例分别为 70%、20% 以及 10%。

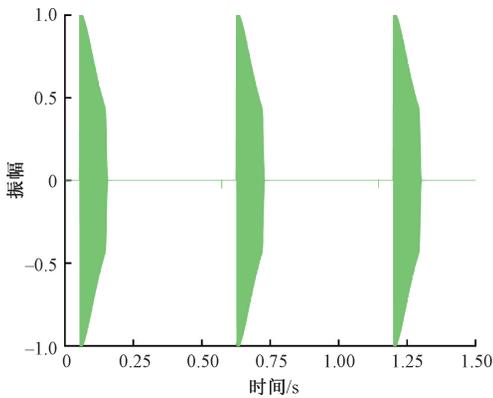
以正常 Sallen-Key 低通滤波电路为例,如图 3 所示,图 3 (a) 为输入信号图,图 3 (b) 为原始数据的波形图,图 3 (c) 为采样成 16 kHz 音频信号后的波形图,图 3 (c) 为音频信号映射成的频谱图,图 3 (d) 输出信号频谱图。



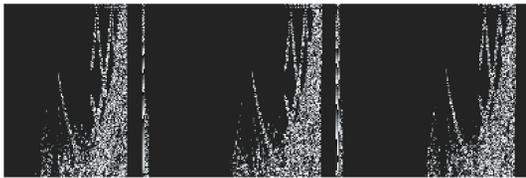
(a) 输入信号波形
(a) Input signal waveform



(b) 正常模拟电路输出信号波形
(b) Signal waveform output form of a normal analog circuit



(c) 采样成音频信号后的波形图
(c) Waveform after sampling into audio signal



(d) 输出信号频谱图
(d) Spectrogram of output signal

图3 数据预处理可视化

Fig. 3 Data pre-processing visualization

2.3 数据增强

为了提高自注意力模型的泛化能力,针对原有数据集进行了数据增强处理。其中,数据增强主要从时域、频域两个方面来实现。为了保证模型效果达到最优,实验中先进行数据划分,再进行数据增强。其中,数据增强的具体的方法为:

1) 随机抖动。模拟电路在运行时,会由于内外部原因的影响导致所输出的信号发生随机抖动。在本文中,我们对信号全局设置了随机抖动来实现增强,抖动的范围设置为(0, 0.05)。

2) 时间缩放。本文对输出信号进行了时间范围调整,即随机缩放一定的倍数,其中缩放倍数的范围为(0.5, 1.5)。实际上对于信号长度的调节,相当于调整了输入信号的周期长度。

3) 电压缩放。本文还对输出信号的电压范围进行了随机缩放的调节,其中随机缩放倍数的范围为(0.8, 1.2)。

4) 随机掩盖。本文还对输出信号进行了随机掩盖的操作,即随机掩盖掉一部分时长信号。掩盖范围为原始信号长度的0~0.25倍。

5) 拼接操作。随机将两端原始输出信号拼接组成一段新的信号。

6) 噪声添加。模拟电路的输出会伴随大量的噪声,包括:白噪声、粉红噪声、约翰逊噪声、量化噪声以及爆米

花噪声等。本文随机选取单一噪声或随机组合多种添加到原始数据中,以实现数据增强的目的。

综上一共有6种数据增强的方法。实验中对每一个原始输出信号都使用了以上的方法实现数据增强,最终每一个输出信号都有对应的99个经过数据增强处理后的信号。这经过数据增强后,数据集相较于原始数据集更加接近于实际应用情况。

以正常输出波形为例,如图4所示,图4(a)为原始的输出信号,图4(b)为在原始信号基础上添加随即抖动后的波形图,图4(c)为原始信号在时间尺度上随机缩放后的波形图,图4(d)为原始信号的电压缩放后的波形图,图4(e)为原始信号添加随机掩盖后的波形图,图4(f)为原始信号经过随机拼接后的波形图,图4(g)为原始信号添加白噪声后的波形图,图4(h)为原始信号添加粉红噪声后的波形图,图4(i)为原始信号同时添加白噪声和粉红噪声后的波形图。

经过数据增强后的数据集的样本量得到了充分的扩充,其分布如表3所示。

表3 数据增强前后数据集比较

Table 3 Comparison of datasets before and after data augmentation

标签	数据增强前的数量	数据增强后的数量
C_{1H}	100	10 000
C_{1L}	100	10 000
C_{2H}	100	10 000
C_{2L}	100	10 000
正常	100	10 000
R_{1H}	100	10 000
R_{1L}	100	10 000
R_{2H}	100	10 000
R_{2L}	100	10 000

3 模拟电路故障检测实验验证

3.1 模型训练

本文以音频频谱图为输入,基于无CNN结构的纯注意力机制建立了模拟电路故障检测的模型。使用SoftMax函数作为模型的输出层的激活函数,将初始学习率设置为0.00005,批量大小设置为12,Dropout率设置为50%,循环迭代轮数为50轮。采用了Adam自适应优化器,设置了5折交叉验证,最终的每一折的准确率与损失值曲线如图5所示。从图中可以看出,准确率、训练损失和验证损失在刚开始训练时会有一定的抖动,但在

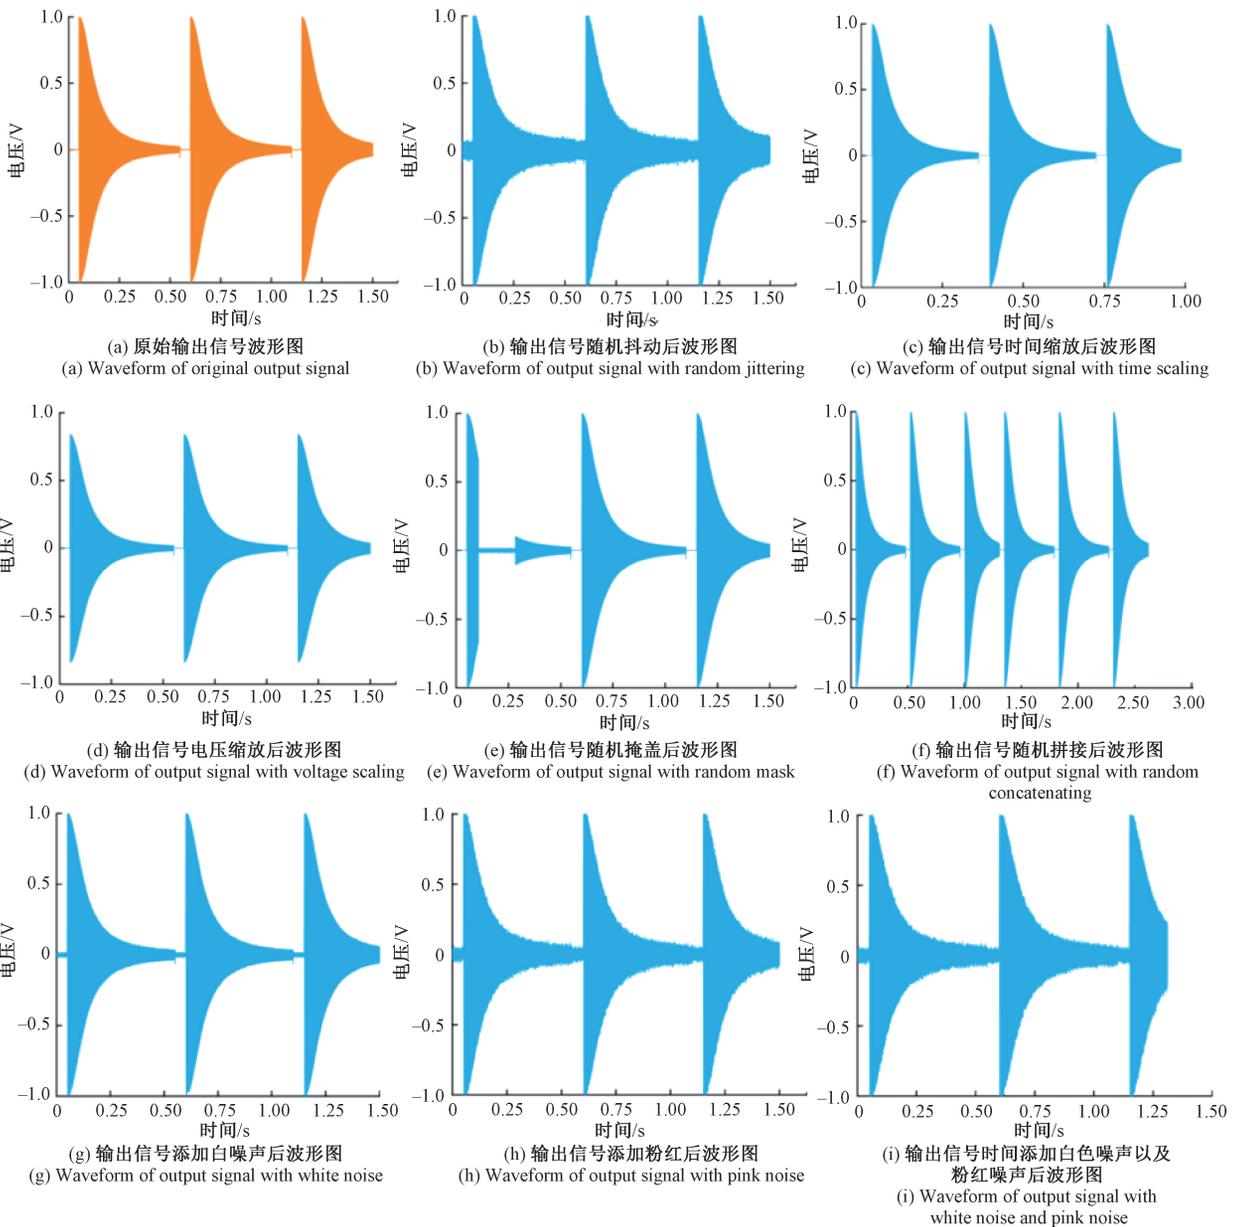


图 4 数据增强可视化

Fig. 4 Data augmentation visualization

接下来的训练的时候,快速地发生了收敛,并且最终收敛的效果是理想的,同时也达到了较高的准确率。此外,如图 5 所示,五折验证里面验证集的损失始终保持比训练集的损失大,这说明了模型并没有发生过拟合,从此也可以看出加入了 Dropout 机制发挥了避免过拟合的作用。

3.2 模型测试

完成训练之后,我们选取了最优模型并结合先前随机抽取数据构成的测试集进行模型性能测试。所得到的混淆矩阵如图 6 所示。根据图 6 计算出在测试集对于各类故障的检测准确率如表 4 所示。该模型对于 $C_1 \uparrow$ 、 $C_1 \downarrow$ 、 $C_2 \uparrow$ 、 $C_2 \downarrow$ 、正常模拟电路、 $R_1 \uparrow$ 、 $R_1 \downarrow$ 、 $R_2 \uparrow$ 以及 $R_2 \downarrow$

的检测准确率分别达到 94.5%、96.4%、97.0%、95.9%、98.1%、89.3%、90.4%、91.7% 以及 92.1%。9 种类型的信号检测平均准确率为 93.9%,其中对于正常模拟电路的检测准确率到最高。

3.3 模型的应用测试

为了测试模拟电路故障检测算法在故障检测工作中的应用效果,搭建了 Sallen-Key 滤波电路进行故障检测测试。如图 7 所示,测试装置包括函数信号发生器、数据采集卡、电源、Sallen-Key 电路测试板以及基于 Labview 编写的模拟电路故障检测程序。其中,信号发生器所产生的信号为频率从 0 Hz 逐步增加至 100 000 Hz,振幅为

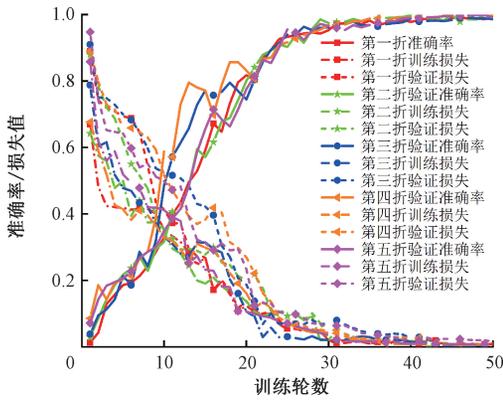


图5 五折交叉验证
Fig. 5 Five-cross validation



图7 用于测试电路故障的实验装置
Fig. 7 Experimental setup for testing circuit faults

数据采集卡产生的信号, 然后进行数据预处理, 最后输入到模型中进行故障诊断。

4 结果分析与对比验证

4.1 结果评估与分析

从检测结果中可以看出, 该模型实现了较为优异的模拟电路故障检测效果, 可以有效检测出正常电路以及其余 8 种故障电路。

基于音频分类的自注意力变换网络对于模拟电路的故障检测准确率高达 98.1%, 平均准确率达到 93.9%, 验证了基于音频分类实现模拟电路故障检测的可行性。

本文还使用了数据增强的方法来从时域和频域两个角度进行扩充数据集, 进一步提高了模型的鲁棒性、泛化能力。从最终的结果可以看出, 尽管使用了不同的数据增强的方法, 模型对于故障诊断具有较高的准确性。

4.2 与其它算法的对比

本文提出的算法的检测效果与其它工作的比较如表 5 所示。

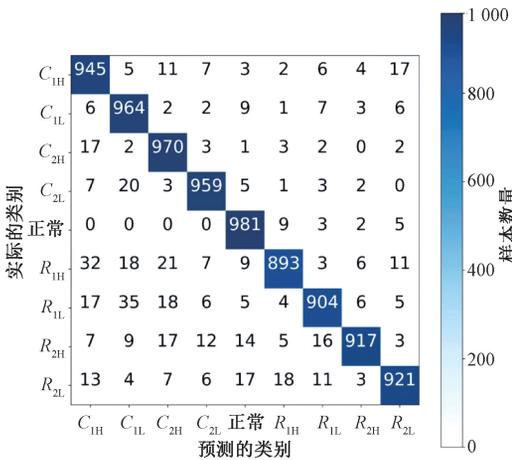


图6 混淆矩阵
Fig. 6 Confuse matrix

表4 各类故障检测准确率

Table 4 Accuracy of various types of fault detection

标签	检测准确率/%
C_{1H}	94.5
C_{1L}	96.4
C_{2H}	97.0
C_{2L}	95.9
正常	98.1
R_{1H}	89.3
R_{1L}	90.4
R_{2H}	91.7
R_{2L}	92.1

表5 算法效果比较

Table 5 Algorithm effects comparison

算法	故障种类	准确率/%
SVM ^[3]	4	97.8
Global SVM ^[4]	4	100.0
FA-TM-ELM ^[4]	9	97.8
RBF ^[6]	9	88.0
Bagging RBF NN ^[15]	9	93.7
Db2 wavelet ^[7]	9	92.5
MAX multi-wavelet ^[7]	9	98.2
1 维 CNN ^[9]	9	97.7
PSD-DCNN ^[8]	9	99.8
本文所提出的算法	9	93.9

1 V, 周期为 0.5 s 啁啾信号以激励测试电路。Sallen-Key 滤波电路测试板可以更换 C_1 、 C_2 、 R_1 、 R_2 模拟 8 种实际类型的电路故障。数据采集卡用于收集电路测试板所产生的信号。模拟电路故障诊断程序首先通过 Labview 接收

从表5中可以看出,所提出的算法效果要优于传统的RBF算法、Db2 wavelet算法,准确率分别提高了5.9%以及1.4%。但相比于其他算法还有一定的差距。本文提出了模拟电路故障检测的问题转换成音频分类问题,并基于音频分类自注意力转换网络实现故障检测的思路。实验结果表明,该方案具有极佳的可行性。

5 结 论

针对模拟电路故障不易检测,现有的模拟电路故障检测算法和典型深度学习算法的不足,以ASL模型为基础,提出了用于模拟电路故障诊断的自注意力机制深度学习算法,将模拟电路的输出信号采样成音频信号,进而将故障检测问题转化为音频分类问题,给未来在更复杂的、更大规模的模拟集成电路故障诊断/定位研究提供了可行的解决方案。

采用频谱变换的技术将原始数据转换成的音频信号映射成频谱图作为算法模型的输入;采用数据增强、Dropout等优化方法,有效防止模型过拟合,提高了检测算法的鲁棒性和泛化能力;最终对模拟电路故障检测的平均准确率达到93.9%。充分验证了本文提出的思路的可行性和有效性。在未来,可以进一步应用于大规模模拟电路的故障诊断。

参考文献

- [1] 谭阳红,何怡刚. 模拟电路故障诊断的新故障字典法[J]. 微电子学, 2001, 31(4): 252-254.
TAN Y H, HE Y G. A new fault dictionary method for fault diagnosis of analog circuits[J]. *Microelectronics*, 2001, 31(4): 252-254.
- [2] 杨士元,胡梅,王红. 模拟电路软故障诊断的研究[J]. 微电子学与计算机, 2008, 25(1): 1-8.
YANG SH Y, HU M, WANG H. Research on soft fault diagnosis of analog circuits[J]. *Microelectronics and Computers*, 2008, 25(1): 1-8.
- [3] ZHANG A, CHEN C. Fault diagnosis based semi-supervised global LSSVM for analog circuit[C]. 2014 International Conference on Mechatronics and Control (ICMC), IEEE, 2014: 744-748.
- [4] YU W X, SUI Y, WANG J. The faults diagnostic analysis for analog circuit based on FA-TM-ELM[J]. *Journal of Electronic Testing*, 2016, 32(4): 459-465.
- [5] HE W M, WANG P L. Analog circuit fault diagnosis based on RBF neural network optimized by PSO algorithm[C]. International Conference on Intelligent

- Computation Technology and Automation, IEEE, 2010, 1: 628-631.
- [6] LIU H, CHEN G, SONG G, et al. Analog circuit fault diagnosis using bagging ensemble method with cross-validation[C]. International Conference on Mechatronics and Automation, IEEE, 2009: 4430-4434.
- [7] HU Y Y, PENG M F, TIAN C L, et al. Analog circuit fault diagnosis using multi-wavelet transform and SVM[C]. Third International Conference on Digital Manufacturing & Automation, IEEE, 2012: 214-217.
- [8] 张朝龙,何怡刚,杜博伦. 基于DBN特征提取的模拟电路早期故障诊断方法[J]. 仪器仪表学报, 2019, 40(10): 112-119.
ZHANG CH L, HE Y G, DU B L. Analog circuit incipient fault diagnosis method based on DBN feature extraction[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(10): 112-119.
- [9] SHOKROLAHI S M, KARIMIZIARANI M. A deep network solution for intelligent fault detection in analog circuit[J]. *Analog Integrated Circuits and Signal Processing*, 2021, 107(3): 597-604.
- [10] YANG H, MENG C, WANG C. Data-driven feature extraction for analog circuit fault diagnosis using 1-D convolutional neural network[J]. *IEEE Access*, 2020, 8: 18305-18315.
- [11] SHEVADE S K, KEERTHI S S, BHATTACHARYYA C, et al. Improvements to the SMO algorithm for SVM regression[J]. *IEEE Transactions on Neural Networks*, 2000, 11(5): 1188-1193.
- [12] LONG B, TIAN S, WANG H. Diagnostics of filtered analog circuits with tolerance based on LS-SVM using frequency features[J]. *Journal of Electronic Testing*, 2012, 28(3): 291-300.
- [13] ALZUBAIDI L, ZHANG J, HUMAIDI A J, et al. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions[J]. *Journal of Big Data*, 2021, 8(1): 1-74.
- [14] HARRISON R R, CHARLES C. A low-power low-noise CMOS amplifier for neural recording applications[J]. *IEEE Journal of Solid-State Circuits*, 2003, 38(6): 958-965.
- [15] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM)

- network[J]. *Physica D: Nonlinear Phenomena*, 2020, 404(1): 1-6.
- [16] YU Y, SI X, HU C, et al. A review of recurrent neural networks; LSTM cells and network architectures [J]. *Neural Computation*, 2019, 31(7): 1235-1270.
- [17] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]. *Advances in Neural Information Processing Systems*, 2017: 5998-6008.
- [18] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words; Transformers for image recognition at Scale [C]. *International Conference on Learning Representations*, 2020: 285-288.
- [19] GONG Y, CHUNG Y A, GLASS J. AST: Audio spectrogram transformer [C]. *2021 Interspeech*, 2021: 571-575.
- [20] DENG L, YU D. Deep learning: Methods and applications [J]. *Foundations and Trends in Signal Processing*, 2014, 7(3): 197-387.
- [21] DEVLIN J, CHANG M W, LEE K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding [C]. *Annual Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, IEEE, 2019: 4171-4186.
- [22] 周勃, 张士伟, 陈长征, 等. 风力机叶片多裂纹扩展声发射信号的特征识别 [J]. *仪器仪表学报*, 2015, 36(1): 110-117.
- ZHOU B, ZHANG SH W, CHEN CH ZH, et al. Feature identification of acoustic emission signals of multiple propagating crack on wind turbine blade [J]. *Chinese Journal of Scientific Instrument*, 2015, 36(1): 110-117.
- [23] DENG J, DONG W, SOCHER R, et al. Imagenet: A large-scale hierarchical image database [C]. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, 2009: 248-255.
- [24] TOUVRON H, CORD M, DOUZE M, et al. Training data-efficient image transformers & distillation through attention [C]. *International Conference on Machine Learning*, PMLR, 2021: 10347-10357.
- [25] GEMMEKE J F, ELLIS D P W, FREEDMAN D, et al. Audio set: An ontology and human-labeled dataset for audio events [C]. *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 2017: 776-780.

作者简介



杨东儒, 2020 年于广东工业大学获得学士学位, 现为广东工业大学硕士研究生, 主要研究方向为深度学习、集成电路设计。

E-mail: YangDRu_gdut_edu@outlook.com

Yang Dongru received his B.Sc. degree from Guangdong University of Technology in 2020. He is currently purchasing his M.Sc. degree at Guangdong University of Technology. His main research interests include deep learning, integrated circuits design.



鲁圣国 (通信作者), 1985 年于华中科技大学获得学士学位, 1988 年于华中科技大学获得硕士学位, 1993 年于西安交通大学获得博士学位, 现为广东工业大学教授, 主要研究方向为微电子材料和器件、柔性电子器件、固态制冷和储能器件集成。

E-mail: sglu@gdut.edu.cn

Lu Shengguo (Corresponding author) received his B.Sc. degree and M.Sc. degree both from Huazhong University of Science and Technology in 1985 and 1988, and received his Ph.D. degree from the Xi'an Jiaotong University in 1993. He is currently a professor at Guangdong University of Technology. His main research interests include microelectronic materials and devices, flexible electronic devices, solid state cooling and energy storage device integration.