

基于 EfficientNetV2 的模拟电路早期软故障诊断

郭旬涛¹, 刘博禹², 刘晓东¹

(1. 哈尔滨工业大学 电信学院, 哈尔滨 150001; 2. 北京机械设备研究所, 北京 100854)

摘要: 针对模拟电路早期软故障诊断困难问题, 提出了一种基于卷积神经网络 EfficientNetV2 的模拟电路早期软故障诊断方法, 该方法使用扫描信号作为被测电路的激励信号, 采集被测电路输出端基于各种软故障的原始信号, 利用连续小波变换进行时频分析, 将输出的时域故障信号转化为二维时频图, 作为 EfficientNetV2 网络的输入, 利用 EfficientNetV2 网络提取模拟电路的故障特征, 确定元件的故障类型, 实现电路的故障诊断, 用 Sallen-Key 带通滤波电路和四运放双二次滤波电路进行了仿真实验; 实验结果表明, 该方法在测试电路上表现优异, 测试电路的诊断准确率均高达 99.6%。

关键词: 模拟电路; 故障诊断; 连续小波变换; 二维时频图; EfficientNetV2

Early Soft Fault Diagnosis in Analog Circuits Based on EfficientNetV2

GUO Xuntao¹, LIU Boyu², LIU Xiaodong¹

(1. School of Telecommunications, Harbin Institute of Technology, Harbin 150001, China;

2. Beijing Institute of Machinery and Equipment, Beijing 100854, China)

Abstract: In order to solve the problem of early soft fault diagnosis in analog circuits, an early soft fault diagnosis method for analog circuits based on convolutional neural network EfficientNetV2 is proposed. This method uses scanning signals as excitation signals for tested circuit, collects the output of tested circuit based on the original signals of various soft faults, performs time-frequency analysis using continuous wavelet transform, and converts the output time-domain fault signal into a two-dimensional time-frequency map. As the input of the EfficientNetV2 network, this network is used to extract the fault features of analog circuits, determine the types of component fault, and achieve fault diagnosis of the circuit. Simulation experiments are conducted on Sallen-Key band-pass filter circuit and four op-amp dual quadratic filter circuit. Experimental results show that this method has excellent performance in tested circuit, with a diagnostic accuracy of up to 99.6%.

Keywords: analog circuit; fault diagnosis; continuous wavelet transform; two-dimensional time-frequency map; EfficientNetV2

0 引言

伴随电子行业的高速发展, 电子系统被广泛应用于飞机、机器人、航空航天等领域。其中模拟电路是电子系统的重要组成部分之一, 模拟电路规模越来越大, 构成电路的器件也越来越多, 其工作环境也越来越复杂, 在一些恶劣环境中, 模拟电路的可靠性会受到影响, 如果在运行时出现故障, 不能快速诊断出故

障, 就会造成严重损失^[1]。另外在电子设备中近 80% 的电路是数字电路, 但造成故障的 80% 都是模拟电路^[2], 且组成数字电路的元器件较为固定、简单, 数字电路中通常只有短路故障、开路故障和卡死故障^[2], 而在模拟电路中, 由于模拟电路的基本特性, 如元件的非线性和容差、故障模型的低效、可达节点的不足以及测量的不确定性等, 使得模拟电路的故障诊断相较于数字电路更加困难, 研究模拟电路的故障诊断是

收稿日期: 2024-03-16; 修回日期: 2024-05-09。

基金项目: 国家自然科学基金(62171157)。

作者简介: 郭旬涛(2000-), 男, 硕士研究生。

通讯作者: 刘晓东(1967-), 男, 博士, 副教授, 硕士生导师。

引用格式: 郭旬涛, 刘博禹, 刘晓东. 基于 EfficientNetV2 的模拟电路早期软故障诊断[J]. 计算机测量与控制, 2025, 33(5): 29

- 36.

非常有必要的,因此,本文提出了一种新的模拟电路的高效软故障诊断方法。

模拟电路的故障可归纳为软故障和硬故障两大类^[2]。硬故障指电路元器件出现短路或断路等重大损坏,可能完全改变电路内部结构和连接方式,导致电路性能完全失效。而软故障则是指元器件在实际运行环境中偏离初始标称值,如电阻值超出正常公差范围,从而使得电路性能与正常状态有所不同^[1]。电路硬故障往往涉及明确的物理损坏或元件失效,例如,断路、短路或元件老化等硬故障^[1],电路在硬故障状态下通常会停止工作甚至造成严重的破坏,硬故障的诊断通常相对较简单,基本可以通过仪器测试迅速定位。相较之下,软故障则很难直接诊断出来,在软故障的初期阶段,即早期故障,由于故障元件超出容差的程度不高,早期故障的故障特征往往不明显,电路在软故障状态下通常还能继续工作,使得诊断的难度提高,需要更加精确的故障诊断方法,因此本文重点研究模拟电路早期软故障诊断。

故障诊断方法一般分为两类:测试后模拟(SAT, simulation after test)和测试前模拟(SBT, simulation before test)^[1],SAT方法是将模拟电路故障诊断问题转化为建模问题,再通过参数识别法、故障验证法等方法,通过实际测试数据确定模型中的参数,从而完成对故障的诊断。随着模拟电子系统越来越复杂,很难再建立精确的数学模型,且SAT方法需要的计算资源也远大于SBT方法。因此目前模拟电路软故障诊断多采用数据驱动的SBT方法,而该方法的核心是对已有的故障数据进行特征提取和故障分类。常见的数据驱动方法有,支持向量机(SVM, support vector machine),BP神经网络,模糊决策树等^[4]。Yuan等^[5]将信号的峰度和熵作为人工神经网络的输入。Xiao等^[6]利用小波变换和核主成分分析(KPCA, kernel principal component analysis)对信号进行预处理,然后将提取的特征输入到人工神经网络中。Chen等^[7]通过小波包分析提取故障特征,并利用基于量子遗传算法的SVM进行电路故障诊断。邓等^[8]采用分数阶小波变换并结合隐马尔科夫模型,完成故障诊断。罗等^[9]采用分数阶小波变换进行特征提取,采用支持向量数据描述进行故障诊断。这些传统方法在面对简单的模拟电路时,均能取得不错的效果,但也存在不少问题,SVM在处理高维数据时可能面临计算复杂度问题,且在选择核函数和参数时敏感度较高。BP神经网络容易受到局部极小值的干扰,对大规模数据集的训练成本较高。模糊决策树在复杂关系和不确定性方面表现不佳。其他方法如小波变换和KPCA对预处理参数敏感,而分数阶傅里叶变换和分数阶小波变换在噪声和非线性故障方面可能缺乏鲁棒性,且这些

方法面对不同电路结构时,还需要人工去调整参数,不能实现自动整定模型参数,特别是当电路变得更加复杂时,这些传统方法很难再有效提取故障的更深层次特征,完成故障诊断任务。

随着深度学习的快速发展,由于其强大的特征提取能力,可以从故障数据中学习到更为丰富、更有表征能力的特征^[10],所以在模拟电路故障诊断领域也很快被利用起来,张等^[11]利用深度神经网络(DBN, deep belief network)对模拟电路进行故障诊断,直接使用原始时域响应信号作为输入。这些方法取得一定不错的效果,但也存在不少问题,直接用原始时域信号作为输入,模型会提取较多的冗余信息,会加大模型学习的难度,同时ResNet网络参数过大,在精度上也有所欠缺^[12],且上述分类模型并没有考虑到实际的物理电路机制。所以为了克服上述问题,本文使用了精度更高,模型参数更少的EfficientNetV2网络来进行故障分类,同时考虑物理电路原理,引入了连续小波变换(CWT, continuous wavelet transform),具有较高的频率分辨率,可以更好的挖掘信号在不同尺度下的特征,减轻了EfficientNetV2的负担,降低对大量训练样本的要求。CWT将电路的时域输出信号转化为二维时频图,作为网络的输入来完成网络的训练。本文以Sallen-Key带通滤波电路和四运放双二次滤波电路容差故障数据作为方法实例进行验证,实验结果表明基于卷积神经网络EfficientNetV2的模拟电路早期软故障诊断方法准确率高达99.6%,效果优异,并与WFF-GMKL-SVM^[13]和ResNet^[14]两种方法进行了对比实验,来进一步验证该方法的有效性。

1 故障特征提取

在早期模拟电路故障诊断中,故障特征通常微弱且难以捕捉^[15],这使得数据驱动的模拟电路故障诊断方法面临挑战。因此,采用一种能够从原始信号中提取丰富有效特征的方法至关重要。提取时域信号特征将其转换成频域,常用傅里叶变换、STFT和小波变换等方法,但傅里叶变换和STFT都存在一定缺陷,傅里叶变换在频域提供了出色的性能,但其对非稳态信号的处理能力有限,尤其对于包含局部故障特征的信号。STFT在时频分析方面具有优势,但其固定窗口大小限制了对不同频率成分的适应性,而且频率分辨率与时间分辨率之间存在权衡。相比之下,连续小波变换因其出色的局部特征提取能力和出色的抗噪性而备受青睐。在本文中,利用连续小波变换来处理原始输入信号。首先,我们使用CWT将原始故障信号 $x(t)$ 从时域转换到时频域,其表示如下:

$$WT_x(a, b) = [x(t), \phi_{a,b}(t)] = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \phi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

其中: $\psi(t)$ 是小波母函数, 通过平移和尺度变换得到小波基函数:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), a > 0, b \in R \quad (2)$$

a 为尺度因子, b 为平移因子, $WT_x(a, b)$ 是小波系数矩阵, 这个矩阵的行对应于不同尺度下的小波函数的缩放参数, 列对应于信号在不同时间上的平移参数。每个元素代表在特定尺度和位置上信号的局部特征 (能量分布), 其大小主要取决于小波母函数的选择, 而常见的小波母函数有 Haar 小波、Symlet 小波、Biorthogonal 小波、Morse 小波等, Haar 小波是简单的正交小波, 特点是紧致支持, 且计算速度快, 适用于信号压缩和基本小波变换。Symlet 小波是对称的小波函数, 继承了 Haar 小波的紧致性, 并提供更多平滑性, 常用于分析非平稳信号。Biorthogonal 小波则是一组非正交小波函数, 具有对称性和更灵活的性质, 适用于处理非平稳信号, 并在信号的时间-频率局部化方面表现出良好性质。Morse 小波具有可变带宽和频率的特性, 适用于对信号的局部频率特性进行更精细分析, 在处理复杂频谱信号时表现出色。经过测试, 发现 Morse 小波对低频分量的检测和分析能力更强, 且具有良好的时频局部化特性和优秀的时间频率分辨率。所以本文选择 Morse 小波作为连续小波变换的小波母函数, 其表示如下:

$$\psi(t) = e^{i2\pi f_c t} \cdot e^{-t^2/2} \cdot P(t) \quad (3)$$

$$P(t) = \frac{1}{\sqrt{a}} \cdot \left(\frac{b}{\pi}\right)^{1/4} \cdot e^{-b(t-a)^2/2a} \cdot e^{i\omega(t-a)} \quad (4)$$

$$\omega = 2\pi f_c \sqrt{1 + \frac{1}{4b^2}} \quad (5)$$

公式 (3) 表示 Morse 小波函数: 其中 $e^{i2\pi f_c t}$ 是一个复指数函数, 表示频率为 f_c 的正弦波或余弦波, f_c 是中心频率。 $e^{-t^2/2}$ 是一个高斯函数, 描述了波形在时间域上的衰减。 $P(t)$ 是一个调制函数, 控制了波形的形状。

公式 (4) 为调制函数 $P(t)$, 包含以下几个部分: $\frac{1}{\sqrt{a}}$: 用于归一化函数, 确保积分后的波函数的能量等于 1。 $\left(\frac{b}{\pi}\right)^{1/4}$: 用于调节波函数的幅度。 $e^{-\frac{b(t-a)^2}{2a}}$: 高斯窗口函数, 决定了波形的频域带宽和时间-频率分辨率。 $e^{i\omega(t-a)}$: 相位调节项, 其中 ω 由公式 (5) 给出。

公式 (5) 计算了相位调节项中的频率参数 ω 。它是一个与中心频率 f_c 和调制参数 b 相关的复数, 用于调整波形的相位, 以便在时频域内获得所需要的特性。

2 EfficientNetV2 网络

本文方法是基于 EfficientNetV2 网络, 所以有必要对该网络作一下详细介绍。EfficientNetV1 是基于组合不同网络尺度 (宽度、深度、分辨率) 的复合缩放方法

构建的, 而 EfficientNetV2 在此基础上进行了更深入的优化和改进, 进一步提升了网络的精度, 降低了网络参数和训练时间, 训练速度较 V1 网络模型有效提升了 11 倍, 同时参数数量减少为原来的 1/6.8^[16], 该模型的基本结构如图 1 所示。




图 1 EfficientNetV2 网络结构

从图 1 中可以看出, EfficientNetV2 主要采用了 Fused-MBConv 和 MB-Conv 模块^[16], 图 2 是这两个模块的结构图。




图 2 Fused-MBConv 和 MB-Conv 模块结构

其中: H 代表输入图像高度, W 代表输入图像宽度, C 代表输入图像的通道数。由于 Depthwise 卷积不能充分利用 gpu 加速, 所以 Fused-MBConv 将 Depthwise 卷积换成了普通的卷积, 且在每个 Conv 卷积层之后, 还额外添加了一个 BN 层, 其激活函数用的是 Swish 函数, 它结合了线性和非线性的特性, 形式类似于 ReLU (Rectified Linear Unit, ReLU), 但使用了 sigmoid 函数的平滑版本。这种结合使得 Swish 在一些情况下能够在梯度下降过程中更好地进行优化, 相较于传统的激活函数如 ReLU, Swish 会产生更平滑的梯度图, 有助于训练更深层的神经网络。Swish 激活函数的数学表达式为:

$$\text{Swish}(x) = x \cdot \text{sigmoid}(x) \quad (6)$$

其中: $\text{sigmoid}(x)$ 是 S 型函数, 即

$$\frac{1}{1 + e^{-x}} \quad (7)$$

同时,这两个模块都引入了基于注意力机制—(SE, squeeze-and-excitation) 模块, SE 模块由两个关键部分组成: 压缩 (Squeeze) 和激励 (Excitation)^[16]。在压缩阶段, SE 模块通过全局平均池化操作来获取每个特征通道的全局统计信息, 将特征图压缩为单个数字, 以捕获每个通道的重要性。在激励阶段, 通过一个或多个全连接层, 对每个通道的重要性进行建模, 得到权重系数, 对特征进行加权, 强化重要特征并抑制不重要的特征。这种机制使得模型能够动态地调整每个通道的权重, 更加关注对任务有益的特征。

通过一系列卷积层、池化层和引入的注意力机制 (SE 模块), EfficientNetV2 对预处理的数据进行特征提取。在这个过程中, 注意力机制动态调整和加权特征图。随着多个卷积层和注意力机制的作用, 特征图逐渐转化为更高级、更抽象的特征表示, 包括图像的纹理、形状、边缘和语义信息等。为了使网络更好地理解整体图像的语义和全局特征, 而不仅仅关注于局部区域的特征, 随后进行全局信息融合。最终, 通过全连接层, 提取的特征被映射到输出类别上, 完成对故障的分类。

3 基于 EfficientNetV2 的模拟电路早期软故障诊断方法

本文提出了一种基于 EfficientNetV2 的模拟电路早期软故障诊断方法, 旨在通过 EfficientNetV2 深度神经网络的强大特征提取能力, 学习模拟电路的非线性故障特征, 解决模拟电路初期软故障诊断问题, 所提出的故障诊断方法流程图如图 3 所示。

所提出方法具体实施步骤:

1) 故障数据集获取。搭建仿真电路, 分别对每个故障类型进行仿真, 并采集电路的时域输出信号, 得到模拟电路早期软故障数据。

2) 时频图的获取。对每个类别的故障数据作连续小波变换, 得到小波变换系数矩阵, 该矩阵包含了故

障数据在不同尺度和位置上的频谱信息, 相比于时域输出信号, 去掉了更多的冗余信号, 保留了更深层次的数据特征, 可以更好的表征故障特征。为了确保不同尺度下的小波变换系数具有可比性, 需要进行归一化处理, 使得它们具有一致的量纲, 同时为了便于映射成图像, 也需要进行归一化处理, 本文采用线性归一化, 将小波变换系数矩阵的值映射到 $[0, 1]$, 具体归一化步骤如下:

1) 计算小波变换系数矩阵 X 的最大值 $X_{\max}$ 和最小值 $X_{\min}$ 。

2) 使用线性归一化方法将小波变换系数矩阵的值映射到 $[0, 1]$ 范围内:

$$X_{\text{normalized}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (8)$$

根据系数的大小, 映射成不同的颜色, 最终将整个系数矩阵映射成彩色 RGB 图像, 再将其压缩成 224×224 大小的图像作为网络的数据输入。

3) EfficientNetV2 网络模型的参数确定。将转化成 RGB 图像的故障数据集按照一定比例, 划分成训练集和验证集, 将训练集送入 EfficientNetV2 网络进行训练, 通过不断迭代优化, 从而确定最优网络参数。

4) 模拟电路故障诊断。使用训练好的模型, 将验证集数据输入模型中, 模型会输出每个故障类型的概率, 将其中概率最大的故障类型判定为最终预测的故障, 最终还会输出混淆矩阵, 来展示诊断结果。

4 仿真与实例分析

为了更好地评估该诊断方法的有效性, 本文基于 Sallen-Key 带通滤波电路和四运放双二次滤波电路进行了仿真实验, 通过两种电路的实验验证了该方法的有效性。一般模拟电路中故障类型分为: 单一故障、多重故障。单一故障是指系统中的一个关键部件出现故障, 而其他部件仍处于正常工作状态。多重故障或耦合故障涉




图 3 故障诊断方法流程图

及两个或多个部件同时发生故障,或一个故障部件导致其他相关部件故障。研究表明,与单一故障相比,多重故障的发生概率较低^[17]。所以本实验只进行模拟电路建模中的单故障仿真,来验证本文所提出的方法。

实验在 Windows 10 操作系统、Intel (R) Xeon (R) Silver 4214RCPU 和 RTX 3080 Ti GPU 的计算机上进行,使用 Multisim14 软件完成仿真电路的搭建与电路输出数据采集,使用 pytorch 实现深度神经网络 EfficientNetV2 的搭建与训练。两个实验电路的电阻值的容差限均设置为 5%,电容值的容差限均设置为 10%,由于研究的是模拟电路早期软故障诊断,因此在本论文中使用元器件偏移标称值 20%作为早期故障^[17],设定的元器件值高于或低于标称值均作为模拟电路故障,模拟电路常用的测试激励信号主要包括正弦信号、扫描信号以及脉冲信号,在本论文中两个实验电路均采用线性扫描信号作为测试激励信号,其幅值为 5 V,频率范围为 1 Hz 到 10 kHz,持续时间为 0.2 s。

4.1 Sallen-Key 带通滤波电路诊断实例

Sallen-Key 带通滤波电路一种基于 Sallen-Key 拓扑结构的二阶滤波器,常用于中频放大器、音频处理和通信系统。其基本结构包括两个共振电路,一个用于高通滤波,另一个用于低通滤波,通过一个放大器连接形成反馈网络,其电路结构^[16]如图 4 所示。




图 4 Sallen-Key 带通滤波电路原理图

由于其结构简单,应用较为广泛。经过灵敏度分析之后,发现元器件 C1, C2, R2, R3, R4, 对电路输出影响较大,所以选择这些元器件作为灵敏度分析的基本元件,由于本文将元器件偏移标称值 20%作为早期故障,因此,可以得到 11 种不同的故障种类,包括无故障 (NF), C1 ↓, C1 ↑, C2 ↓, C2 ↑, R2 ↓, R2 ↑, R3 ↓, R3 ↑, R4 ↓, R4 ↑, 其中 ↑ 代表超过标称值, ↓ 代表低于标称值,表 1 列出了 Sallen-Key 带通电路各部件的故障类别、标称和故障值,每个编号只存在一个元器件发生一种故障,其它元器件正常工作。对于每一种故障种类,本文采用 320 次蒙特卡洛分析,因此 Sallen-Key 带通电路有 3 200 个故障样本,320 个非故障样本。

表 1 Sallen-Key 带通滤波电路的故障编号,早期故障类别,标称值,故障值

编号	早期故障类别	标称值	故障值
F0	NF	—	—
F1	C ₁ ↓	5 nF	4 nF
F2	C ₁ ↑	5 nF	6 nF
F3	C ₂ ↓	5 nF	4 nF
F4	C ₂ ↑	5 nF	6 nF
F5	R ₂ ↓	3 kΩ	2.4 kΩ
F6	R ₂ ↑	3 kΩ	3.6 kΩ
F7	R ₃ ↓	2 kΩ	1.6 kΩ
F8	R ₃ ↑	2 kΩ	2.4 kΩ
F9	R ₄ ↓	4 kΩ	3.2 kΩ
F10	R ₄ ↑	4 kΩ	4.8 kΩ




图 5 Sallen-Key 带通滤波电路故障图谱

对故障数据作 CWT,得到小波变换系数矩阵,将系数矩阵进行归一化处理,将其映射成彩色 RGB 图像,图 5 展示了 Sallen-Key 带通滤波器的 11 种故障模式的图谱,可以看出图谱中蕴含了丰富的故障信息,有的故障差别用肉眼难以分辨,然后将这些故障数据按照 7: 3 的比例划分为训练集和测试集^[18],用以模型的训练和验证。

经过了 200 轮训练,获得了最优的 EfficientNetV2 模型,图 6 是模型训练过程,模型在 150 轮左右时,基本收敛,最后模型在训练集上准确率达到了 99.9%,之后使用测试集验证最优训练模型的检测精度,同时输出混淆矩阵,来表示电路的检测故障结果,混淆矩阵中的每一列代表了预测类别,每一列的总数表示预测为该类别的数据的数目,每一行代表了数据的真实归属类别,每一行的数据总数表示该类别的数据实例的数目^[18]。

从图 7 混淆矩阵中可以看出每个故障类别共有 95 张测试图片,其中 7 个故障类别均被完全正确识别,但在 F2、F4、F0 和 F10 故障预测中,分别有一个被误判为了 F10、F8、F9 和 F6 故障,这可能是由于 F2、F4、F0 和 F10 故障的特征与 F10、F8、F9 和 F6 故障的特征有一定相似,导致模型在区分这些故障类别时发生混淆。

为了验证本方法的性能,并与现有的模拟电路故障




图 6 基于 Sallen-Key 电路数据集训练的准确率和损失值曲线




图 7 基于 Sallen-Key 数据集的混淆矩阵

诊断算法进行对比，选择了 WFF-GMKL-SVM 和 Res-Net 两种算法进行实验，前者是机器学习中的经典算法，后者是目前较为流行的基于深度学习的方法，且这两种方法在故障诊断领域都取得了很高的精度，所以选取了这两种典型算法进行对比。表 2 展示了 3 种算法在模拟电路故障诊断方面的结果对比。

从表 2 可以明显看出，在准确率方面，本文方法表现最为优越，达到了 99.6%。相较于 ResNet，准确率提升了 8% 左右，而与 WFF-GMKL-SVM 相比也有约

2% 的精度提升。这些结果明确显示了本文方法在模拟电路故障诊断方面的卓越性能。与 WFF-GMKL-SVM 相比，我们的方法在诊断性能上取得了显著的提升，显示了深度神经网络在处理复杂模拟电路故障时的优越性。与 ResNet 相比，本文方法进一步提升了准确率，这可能是得益于 CWT 对信号特征的更全面提取以及比 ResNet 更强大的分类模型^[19]。

表 2 在 Sallen-Key 带通滤波电路上 3 种算法准确率对比

方法	准确率
本文方法	99.6%
WFF-GMKL-SVM ^[13]	97.63%
ResNet ^[14]	91.94%

4.2 四运放双二次滤波电路诊断实例

四运放双二次滤波电路采用了 4 个运算放大器（运放）来构建，以实现更复杂的滤波功能。其基本结构如图 8 所示，包括两个独立的二阶滤波器，每个滤波器都由一个运放和一组电阻、电容组成^[20]。这两个滤波器可以分别实现高通和低通滤波功能。这样的设计使得滤波器具有更高的阶数和更复杂的频率响应。较 Sallen-Key 带通滤波电路结构也更为复杂，加大了其故障诊断的难度。对该电路进行灵敏度分析之后，发现 C1, C2, R1, R2, R3 对电路输出影响较大^[21]，因此选择这些器件作为灵敏度分析的基本元件。可以得到 11 种不同的故障种类，包括无故障（NF），C1↓，C1↑，C2↓，C2↑，R1↓，R1↑，R2↓，R2↑，R3↓，R3↑。表 3 列出了四运放双二次滤波电路各部件的故障类别、标称和故障值。仍然采用 320 次蒙特卡洛分析，因此四运放双二次滤波电路有 3 200 个故障样本，320 个非故障样本。




图 8 四运放双二次滤波电路原理图

表 3 四运放双二次边带滤波器的故障代码, 早期故障类别, 标称值, 故障值

编号	早期故障类别	标称值	故障值
F0	NF	—	—
F1	C1 ↓	5 nF	4 nF
F2	C1 ↑	5 nF	6 nF
F3	C2 ↓	5 nF	4 nF
F4	C2 ↑	5 nF	6 nF
F5	R1 ↓	6.2 kΩ	4.96 kΩ
F6	R1 ↑	6.2 kΩ	7.44 kΩ
F7	R2 ↓	6.2 kΩ	4.96 kΩ
F8	R2 ↑	6.2 kΩ	7.44 kΩ
F9	R3 ↓	6.2 kΩ	4.96 kΩ
F10	R3 ↑	6.2 kΩ	7.44 kΩ

将故障数据通过 CWT 和映射后变成彩色 RGB 图像, 图 9 展示了四运放双二次滤波电路的 11 种故障模式的图谱, 可以看出相比于 Sallen-Key 带通滤波电路的图谱, 四运放双二次滤波电路的图谱更加复杂, 难以由肉眼分辨, 然后将这些故障数据按照 7 : 3 的比例划分为训练集和测试集, 用以模型的训练和验证。




图 9 四运放双二次滤波电路故障图谱

从图 10 可以看出模型大约在训练了 100 轮时, 基本实现了收敛, 表现出比在 Sallen-Key 带通滤波电路数据集上更快的训练速度。从图 11 最终的混淆矩阵可以看出模型的故障诊断效果良好, 每个故障类别的准确率均在 98% 以上, 大部分类别的准确率达到 100%, 但在 F2、F4 和 F0 故障预测中, 存在一到两张图片被误判为其它故障的情况, 可能是数据集过少, 模型学习到了相似的特征, 造成了误判。表 4 是本方法和其它方法在该电路上精度的对比实验。

表 4 在四运放双二次滤波电路上 3 种算法准确率对比

方法	准确率
本文方法	99.6%
WFF-GMKL-SVM ^[13]	95.69%
ResNet ^[14]	92.97%




图 10 基于四运放双二次滤波电路数据集的训练准确率和损失值曲线

由表 4 可知: 在准确率上, 本论文方法的效果最好, 达到 99.6%, 相较于 ResNet 准确率提升了 7% 左右, 而与 WFF-GMKL-SVM 相比也有约 4% 的精度提升, 但由于电路变得更加复杂, WFF-GMKL-SVM 方法在四运放双二次滤波电路上的准确率要低于 Sallen-Key 带通滤波电路, 这可能是由于其基于 SVM, 所以在面对更复杂的故障样本时, 没有提取出不同故障之间




图 11 基于四运放双二次滤波电路数据集的混淆矩阵

更深层次的差异, 而本方法准确率仍保持不变, 这表明

本文所提出的方法在处理复杂电路的故障分类问题上更为有效,为电路故障诊断领域提供了有力的解决方案。

5 结束语

传统的基于 SVM、BP 神经网络等模拟故障诊断方法,直接使用原始时域信号作为输入,对于早期故障诊断或复杂电路诊断的性能仍然不足^[22],且需要人工去大量试验,调整模型参数。而基于深度神经网络的故障诊断方法,则存在精度不足,模型参数过大等问题。为了克服上述问题,本文提出了一种新的故障诊断方法,先利用连续小波变换提取出原始时域信号丰富的时频特征,再进行归一化映射成 RGB 图像,通过模型精度更高、参数更少的 EfficientNetV2 网络进行训练,完成故障诊断任务。在偏移标称值 20% 的情况下,基于 Sallen-Key 带通滤波电路和四运放双二次滤波电路,进行了仿真实验,验证了所提方法的有效性,本方法在两种电路上均达到了 99.6% 的准确度,高于现有的两种方法,但仍有一定的进步空间,未来我们将研究更复杂的电路故障诊断和多故障类型诊断问题。

参考文献:

- [1] LU D, WENG Q. A survey of image classification methods and techniques for improving classification performance [J]. International journal of Remote sensing, 2007, 28 (5): 823–870.
- [2] BINU D, KARIYAPPA B S. A survey on fault diagnosis of analog circuits: Taxonomy and state of the art [J]. AEU-International Journal of Electronics and Communications, 2017, 73: 68–83.
- [3] 欧阳洁. 基于 PCA-LDA 算法的模拟电路复杂故障在线诊断研究 [J]. 计算机测量与控制, 2022, 30 (11): 11–16.
- [4] 张朝龙, 何怡刚, 袁莉芬, 等. 基于 GMKL-SVM 的模拟电路故障诊断方法 [J]. 仪器仪表学报, 2016, 37 (9): 1989–1995.
- [5] YUAN L, HE Y, HUANG J, et al. A new neural-network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor [J]. IEEE Transactions on Instrumentation and Measurement, 2009, 59 (3): 586–595.
- [6] XIAO Y, HE Y. A novel approach for analog fault diagnosis based on neural networks and improved kernel PCA [J]. Neurocomputing, 2011, 74 (7): 1102–1115.
- [7] CHEN P, YUAN L, HE Y, et al. An improved SVM classifier based on double chains quantum genetic algorithm and its application in analogue circuit diagnosis [J]. Neurocomputing, 2016, 211: 202–211.
- [8] 邓 勇, 师奕兵, 张 伟. 基于 FRWT 的模拟电路早期故障诊断 [J]. 仪器仪表学报, 2012, 33 (3): 555–560.
- [9] 罗 慧, 王友仁, 崔 江. 基于最优分数阶傅里叶变换的模拟电路故障特征提取新方法 [J]. 仪器仪表学报, 2009, 30 (5): 997–1001.
- [10] 吉 蒙, 郭玉伟, 王卜瑶, 等. 模拟电路仿真与故障字典生成方法 [J]. 计算机测量与控制, 2023, 31 (11): 124–130.
- [11] 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.
- [12] JI L, FU C, SUN W. Soft fault diagnosis of analog circuits based on a ResNet with circuit spectrum map [J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2021, 68 (7): 2841–2849.
- [13] GAO T, YANG J, JIANG S. A novel incipient fault diagnosis method for analog circuits based on GMKL-SVM and wavelet fusion features [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1–15.
- [14] TARG S, ALMEIDA D, LYMAN K. Resnet in resnet: Generalizing residual architectures [J]. Arxiv Preprint Arxiv: 1603. 08029, 2016.
- [15] 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.
- [16] SUNIL C K, JAIDHAR C D, PATIL N. Cardamom plant disease detection approach using EfficientNetV2 [J]. Ieee Access, 2021, 10: 789–804.
- [17] WANG H. Fault diagnosis of analog circuit based on wavelet transform and neural network [J]. Archives of Electrical Engineering, 2020, 69 (1): 175–185.
- [18] RAWAT W, WANG Z. Deep convolutional neural networks for image classification: A comprehensive review [J]. Neural computation, 2017, 29 (9): 2352–2449.
- [19] SUNIL C K, JAIDHAR C D, PATIL N. Cardamom plant disease detection approach using EfficientNetV2 [J]. IEEE Access, 2021, 10: 789–804.
- [20] LUO H, WANG Y, CUI J. A SVDD approach of fuzzy classification for analog circuit fault diagnosis with FWT as preprocessor [J]. Expert Systems with Applications, 2011, 38 (8): 10554–10561.
- [21] 宋国明, 王厚军, 姜书艳, 等. 一种聚类分层决策的 SVM 模拟电路故障诊断方法 [J]. 仪器仪表学报, 2010, 31 (5): 998–1004.
- [22] 何朝劼, 于文震, 郑元珠. 基于 WPPE-RF 的模拟电路故障诊断 [J]. 计算机测量与控制, 2021, 29 (8): 31–36.