

实复域多尺度多层次融合的复合故障定位方法

宋佳宇 高雪莲 陈哲煊

(华北电力大学电气与电子工程学院 北京 102206)

摘要: 针对模拟电路多故障并发的定位问题,提出了一种实复域相结合的定位算法。在实数域利用空间和通道注意力机制的不同操作,在控制网络深度和参数数量的同时获取完整数据特征;在复数域利用复数卷积神经网络跨越层级产生的差异,通过跳跃联接构建深浅层特征融合结构,保留了易丢失的浅层信息并将其与深层信息融合后得到复数域特征。将实复域特征融合用于模拟电路复合故障定位研究,定位平均准确率均在85%以上,最高准确率达到100%。该方法具有较强的稳定性和鲁棒性,为模拟电路复合故障定位研究提供了可行性方案。

关键词: 复合故障定位;注意力机制;复数卷积;特征融合

中图分类号: TH407;TN37 **文献标识码:** A **国家标准学科分类代码:** 470.40

Compound fault location algorithm based on multi-scale and multi-layer feature fusion in real domain and complex domain

Song Jiayu Gao Xuelian Chen Zhexuan

(School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: To tackle the challenge of multiple concurrent fault localization in analog circuits, we propose a localization algorithm that integrates both real and complex domains. In the real domain, comprehensive data features are extracted by employing various operations of spatial and channel attention mechanisms, while simultaneously managing network depth and parameter amount. Within the complex domain, we capitalize on the disparities emerging across layers within a complex-valued convolutional neural network. Through skip connections, a deep-shallow feature fusion structure is formulated, ensuring that shallow information susceptible to loss is preserved and integrated with deep information to yield complex-domain features. The integration of real and complex domain features is subsequently applied to the research on composite fault localization in analog circuits, yielding an average localization accuracy exceeding 93% and a peak accuracy reaching 100%. This approach demonstrates robust stability and reliability, furnishing a viable solution for the ongoing research on composite fault localization in analog circuits.

Keywords: compound fault location; attention mechanism; complex valued convolution; feature fusion

0 引言

电子设备主要由数字电路和模拟电路组成。理论分析和实验数据表明,和数字电路相比,通常80%的故障发生在模拟电路部分。因此及时判断模拟电路的故障情况是保障系统能够正常运行的关键,特别是对模拟电路的故障诊断定位问题,是高度集成的电子电路故障诊断的难点问题^[1-2]。

现代模拟故障定位方法多选用输出电压、电流等时间序列信号作为原始故障信号集,利用时域数据进行故障诊断的研究较为广泛^[3-4]。近年来,卷积神经网络(convolutional neural network, CNN)和注意力机制的引入成功解决了基于数据处理定位方法所带来的特征重叠问

题^[5-6],使时序数据故障定位获得了良好效果。文献[7]将采集到的时间序列输入CNN中,显著提高了结构性电路故障的定位正确率。文献[8]利用通道注意力机制动态融合多通道特征信息,更有效地提取故障特征信息。在此基础上,文献[9]还利用空间注意力机制为重要的空间特征赋值,提高了算法性能。以上故障定位方法都采用单一尺度卷积核进行特征提取,不适用于复杂电路响应信号的特征获取。因此,文献[10-11]建立多尺度卷积核学习框架,利用不同尺寸的并行卷积核提取更完整的故障特征。文献[12]利用多尺度卷积层提取特征并融合后,添加了空间注意力机制和通道注意力机制,增强了模型对不同故障的区分度,但是多分支特征简单连接又会导致特征参

数激增,使得训练成本增加。文献[13]将通道注意力机制添加到多尺度结构的各个分支中,降低了网络的深度。但随后又添加了空间注意力机制和自注意力机制,再次增加网络深度和训练时间且对准确率无明显提升。可见目前研究中,空间注意力机制和通道注意力机制的使用,或者是机制模块的简单融合联接导致参数激增,或者是增加了网络深度,牺牲了训练时间,但准确率提高有限。

文献[14]提出了复数卷积神经网络(complex-valued convolutional neural networks, CCNN)的核心组成,并将CCNN用于语音转录获得良好效果。近年来,有学者借鉴此思想,将时域信号变换到复数域再进行故障定位,文献[15]将复数卷积(complex-valued convolution, CCN)、复数批归一化(complex-valued batch normalization, CBN)用于特征提取,但是该方法为了获得复数域样本集,就将样本实部通过卷积处理得到虚部,造成复数域样本集的虚部和实部特征重叠,失去了虚部该有的数据特征。同样是针对时序数据进行诊断,文献[16]利用快速傅里叶变换(fast Fourier transform, FFT)将数据集映射到复数域,分别建立实数域和复数域的特征提取网络,最后通过实数域与复数域的联合特征对轴承故障进行定位,定位结果优于传统方法。该定位方法的核心是通过增加实数域和复数域的卷积网络层数提高特征提取能力,但随着卷积层数增加,算法模型出现退化现象,容易丢失浅层网络的特征。

在已经有诊断工作的基础上,针对模拟电路中多器件同时发生故障情况下的定位识别率低下问题,本文结合实数域和复数域的数据特征,提出一种实数域和复数域相结合的复合故障定位算法。在实数域部分,通过合理利用空间注意力机制和通道注意力机制,解决了数据冗余和网络结构复杂的问题;在复数域部分,将深层和浅层网络获得的特征进行跳跃融合,解决了复数神经网络中的算法退化现象。

本研究首先在实域中采用并行的大、中、小尺度卷积核对数据进行预处理,利用空间注意力机制保留数据的浅层特征,融合浅层特征后,再利用通道注意力机制增强特征,两种注意力机制在有效控制网络深度的同时,充分提取实域特征;同时通过FFT变换获得复数域样本,再通过复数卷积逐步提取信号在复数域的深层与浅层信息,然后利用跳跃联接操作实现深浅层特征的融合,确保复数域特征提取不丢失浅层特征;最后将实数域与复数域不同尺度和不同深度的特征融合,在分类器中实现故障识别和定位。

1 故障定位算法介绍

1.1 实数域的多尺度特征提取网络

1) 多尺度卷积

CNN是一种前馈神经网络,主要由卷积层、激活函数层和池化层组成。卷积层是网络的核心,利用卷积核移动能获得局部视野,卷积核在整个视野中共享权重矩阵。激活函数层采用ReLU作为激活函数,其定义如式(1)所示。

$$f(x) = \max(0, x) \quad (1)$$

传统的CNN结构中,卷积核尺度单一,卷积层只能提取固定尺度的特征。本研究构造了3个并行卷积层分支,利用大、中、小3个尺度的卷积核处理原始数据,结构如图1所示。

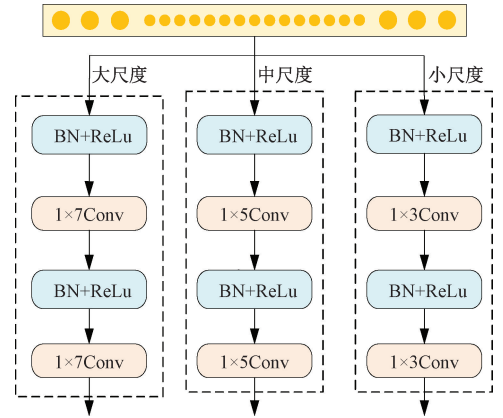


图1 多尺度卷积层

Fig. 1 Multi-scale convolution layer

2) 空间注意力层与通道注意力层

池化层是卷积神经网络中的另一个重要部分,常见的池化操作主要是最大池化和平均池化。在卷积层间插入池化层,可以减少参数的数量和计算成本,有效抑制过拟合现象。空间注意力机制和通道注意力机制都包括最大池化和平均池化操作,不同的是前者对两种池化结果执行并置操作,后者执行相加操作。并置池化结果有利于保留数据特征,而池化结果相加操作能有效减少参数数量,降低计算复杂度。

空间注意力机制如式(2)所示。

$$F_{OSAM} = \sigma(f([\text{Avg}(F_s); \text{Max}(F_s)])) \quad (2)$$

其中, F_s 表示空间注意力机制的输入, F_{OSAM} 表示空间注意力机制的输出, Avg、Max 分别表示平均池化和最大池化, f 是卷积层, σ 表示 sigmoid 函数。

通道注意力机制如式(3)所示。

$$F_{OCAM} = \sigma(MLP(\text{Avg}(F_c)) + MLP(\text{Max}(F_c))) \quad (3)$$

其中, F_c 表示通道注意力机制的输入, F_{OCAM} 表示通道注意力机制的输出, Avg、Max 分别表示平均池化和最大池化, MLP 是多层感知连接层, σ 表示 sigmoid 函数。

基于这样的考虑,为了缩减网络深度,多尺度特征提取利用空间注意力机制实现池化操作,因为空间注意力机制中两种池化结果的并置操作能够有效保留数据特征,与此同时,空间注意力机制利用两种池化操作也减弱了卷积层对时序样本的时间先后敏感性。为了降低参数数量,利用通道注意力机制中的最大池化和平均池化的相加操作能够有效降低参数维度,并增强特征提取效果。

空间注意力机制扩充通道的同时也引入了不必要的冗余数据,因此添加了一层卷积去除冗余,构成空间注意力层

(spatial attention mechanism layer, SAML);通道注意力机制同理构成通道注意力层(channel attention mechanism

layer, CAML)。空间注意力层和通道注意力层如图 2 和 3 所示。




图 2 空间注意力层

Fig. 2 Spatial attention mechanism layer




图 3 通道注意力层

Fig. 3 Channel attention mechanism layer

3) 实数域多尺度特征提取网络

经过多尺度卷积层后,3 个分支分别接入空间注意力层,利用池化并置操作,突出需要关注的数

据片段,充分提取数据特征;然后将 3 个分支的特征在同一维度下联接以实现特征融合;最后利用通道注意力层的池化相加操作,降低参数维度,增强了特征提取的效果。基于此,本文提

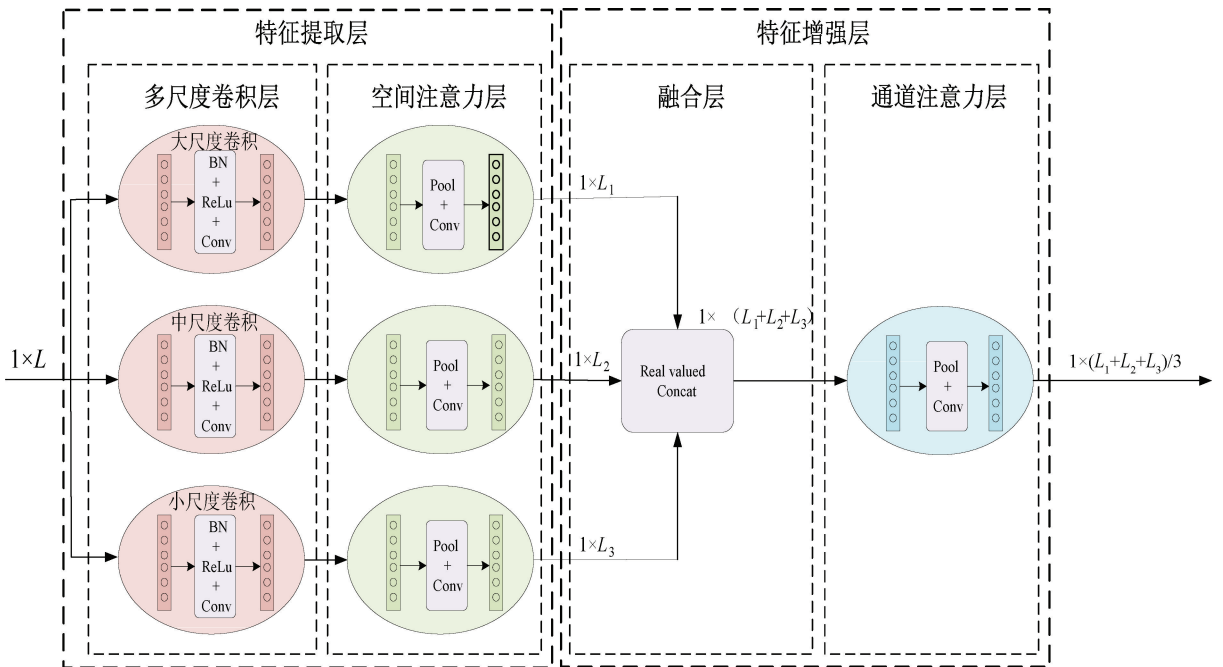


图 4 实数域的多尺度特征提取网络

Fig. 4 Multi-scale features extraction network in real domain

1.2 复数域的多层次特征提取网络

1) 复数卷积

复数具有丰富的表征能力,但由于复数卷积、复数归一化和复数激活函数难以实现,因此复数卷积神经网络应用较少。自 Trabelsi 等^[14]提出 CCNN 的核心模块后,CCNN 广泛应用于时序样本的诊断和预测问题。复数卷

积中,假设复数的实部和虚部分别代表两个通道,因此对应的复数卷积核的输入由两个通道组成,卷积核的输出也由两个通道组成。令复数样本集为 $h = X_i + iY_i$,卷积核矩阵为 $W = A_i + iB_i$,复数样本和卷积核矩阵的复数卷积操作如图 5 所示。




图5 复数卷积网络

Fig. 5 Complex-valued convolution network

2) 复数域的多层次特征提取网络

为了获得复数域样本,采用 FFT 变换将样本的时域形式转换成频域的复数形式,从而形成复数域样本集。该复数域样本集的实部是通过将时域信号与余弦波相乘并求和得到的,表示信号中各个频率成分的余弦部分的加权和,虚数部分是时域信号与正弦波相乘并求和得到的,表示信号中各个频率成分的正弦部分的加权和。复数域的多层次特征提取网络完整结构如图 6 所示。

图 6 中,CCNN 模块中,输入复数域样本,先通过 CBN 后,再分别对实部和虚部进行 ReLU 操作,最后对复数域样本进行 CCN 操作,以提取特征信息。复数 Concat 模块中,将两个复数样本数据的实部和虚部分别相加后,再组成一个复数数据。

在获得复数样本集后,将数据输入到以 CCNN 为主的特征提取网络中,如果只是通过增加 CCNN 层数提取复数域特征,随着卷积层数增加,CCNN 同样存在退化现象,相对深层网络提取的特征而言,也更容易丢失浅层网络提取到的特征。为此,在 CCNN 的基础上,引入了深浅层特征融合的思想。首先控制 CCNN 中卷积核大小使得深层网络提取到的特征与浅层网络提取到的特征大小相等,再将浅层网络的特征与深层网络的特征执行复数 Concat 操作。其中,深层与浅层网络之间相差两个 CCNN 层,如图 6 中,利用 1 个和 3 个 CCNN 层形成深浅层特征融合结构 1,利用 2 个和 4 个 CCNN 层形成深浅层特征融合结构 2。将这两个深浅层特征融合结构的结果进行复数卷积和复数 Concat 操作,再通过 CCNN 层后获得最终的复数域特征。

考虑到复数域的特征提取网络深度问题和最终的跨层级融合效果,将深层、浅层特征融合结构中的跨越层级数设定为两个,在控制网络深度的基础上,能充分利用跨层级之间的特征差异,保留容易被多层卷积弱化的浅层信息,并实现深浅层特征的融合。

图 6 在复数域的多层次特征提取网络中,将多层 CCNN 中加入跳跃融合操作,将该网络划分成两个深浅层特征融合结构,每个融合结构利用两个 CCNN 层之间的特征差异,这样既能丰富样本特征,也能在网络深度有限的结构中充分保留浅层特征,丰富了样本特征多样性。

1.3 基于实数域多尺度与复数域多层次融合的多故障定位方法

本文在实数域多尺度卷积神经网络的基础上,利用多尺度卷积和双重注意力机制提取时域特征,特别是利用了空间注意力机制和通道注意力机制的不同操作特点,在控制网络深度和参数个数的情况下,获得完整实数域特征。

将实数域样本通过 FFT 变换,获得复数域样本集。对复数域样本集数据,通过多层 CCNN 网络结构进行特征提取,为了防止浅层信息的丢失,同时考虑到跨层级之间的特征差异性,最后利用两个层级的差异,通过跳跃联接方式,形成两个深浅层相结合的特征融合结构,即保留了浅层信息,又在不增加网络复杂性的前提下,融合深浅层的复数域数据特征。

最后将实数域和复数域的特征进行融合操作,选用复数域的样本幅度作为特征量,与实数域特征进行拼接形成的特征量,作为整个实复域特征提取网络获得的数据特征,融合操作如式(4)所示。

$$Y_o = [x_1, x_2, \dots, x_n, y_1, y_2, \dots, y_m] \quad (4)$$

其中, x_n 表示实数域特征量, y_m 表示复数域特征量, Y_o 表示实数域和复数域的特征提取网络输出。

最后利用全连接网络作为分类器, 实现模拟电路的故障定位。基于实数域多尺度和复数域多层次融合的模拟电路复合故障定位方法如图 7 所示。

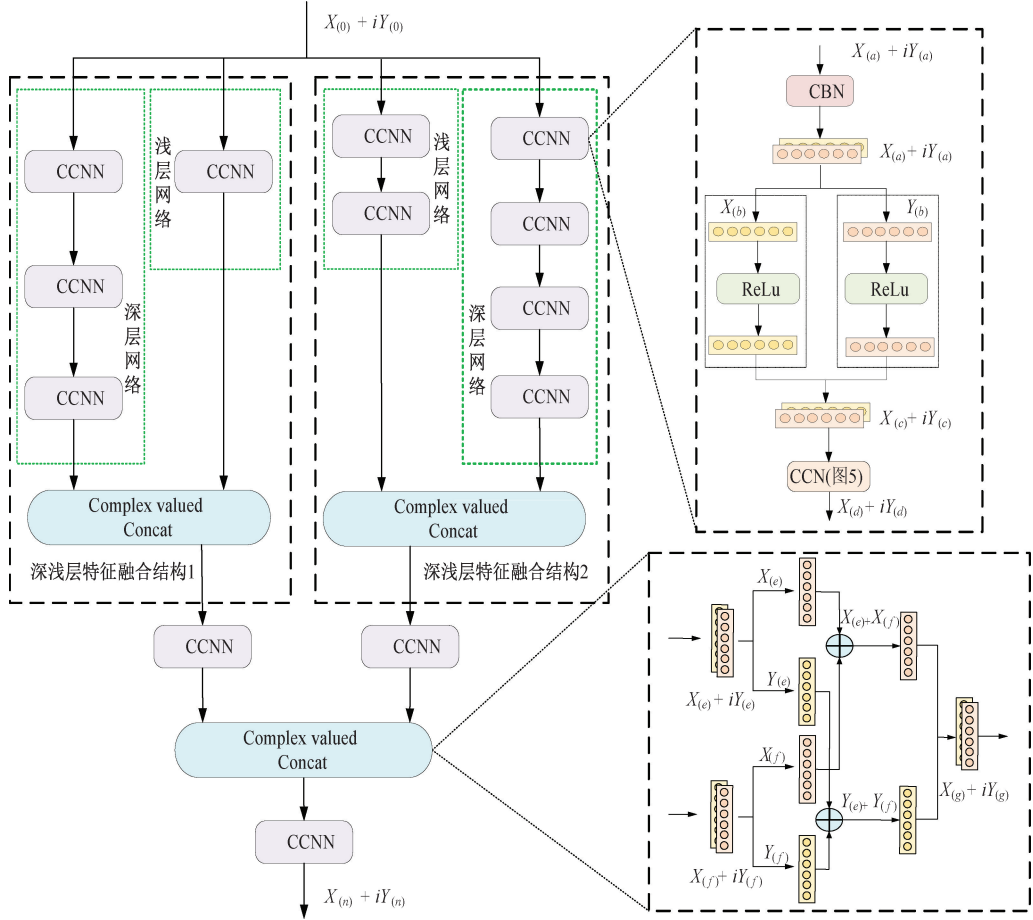


图 6 复数域的多层次特征提取网络

Fig. 6 Multi-layer features extraction network in complex domain

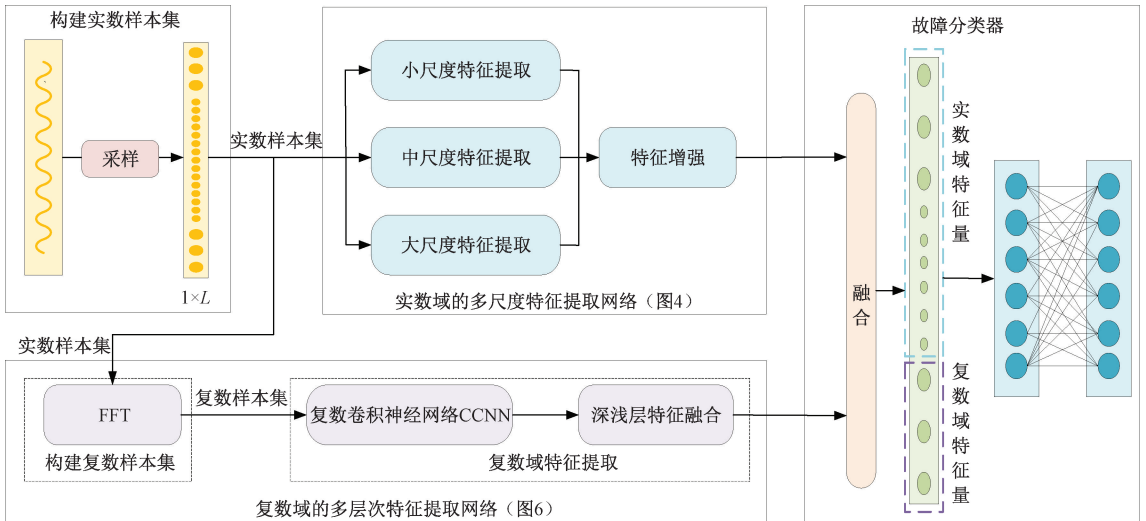


图 7 基于实数域多尺度与复数域多层次融合的故障定位方法

Fig. 7 Fault location method based on feature fusion in real domain and complex domain

2 实验验证

2.1 实验设置

为了验证本研究提出的模拟电路复合故障定位方法的有效性,选择 Sallen-Key 低通滤波器作为测试对象。Sallen-Key 低通滤波器是由 5 个电阻、2 个电容、AD648A 型运算放大器和 ±15 V 双电压电源组成的电路,其原理图如图 8 所示。

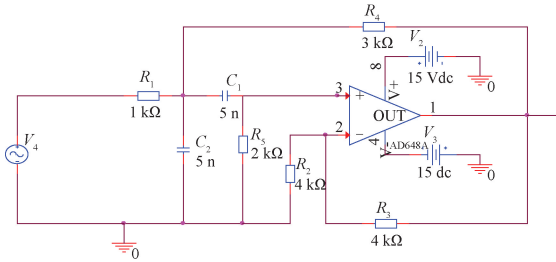


图 8 Sallen-Key 仿真电路

Fig. 8 Sallen-Key simulation circuit

通过电路敏感性分析可知,电路对电容 C_1 与 C_2 最为敏感,因此本文将 C_1 和 C_2 作为故障元器件。当元器件的值大于或者小于标准值的 20% 时,视为出现故障。以 $X \uparrow$ 或 $X \downarrow$ 代表大于标准值 20% 或小于标准值 20%,其中 X 为出故障的元器件。故障元器件的标准值、故障值以及对应的故障标签如表 1 所示。

表 1 故障类型及故障标签

Table 1 Fault types and fault labels

故障标签	故障类型	标准值/nF	故障值/nF
0	正常	—	—
1	$C_1 \downarrow$	5	4
2	$C_1 \uparrow$	5	6
3	$C_2 \downarrow$	5	4
4	$C_2 \uparrow$	5	6
5	$C_1 \uparrow C_2 \uparrow$	5,5	6,6
6	$C_1 \downarrow C_2 \downarrow$	5,5	4,4
7	$C_1 \uparrow C_2 \downarrow$	5,5	6,4
8	$C_1 \downarrow C_2 \uparrow$	5,5	4,6

在 PSPICE 上搭建电路模型获得故障电路的原始数据集,具体实验设置如下:

1) 设置器件参数。输入信号为频率 1 KHz 的交流正弦信号,电路器件的容差设置成 5%。


2) 获取数据集。改变器件参数,并通过蒙特卡洛方法对输出节点进行电压信号采集,每种故障类型分别得到 200 个样本,每个样本包含 500 个抽样点。

3) 划分数数据集。将上述原始数据集随机划分为训练集和测试集,比例是 4:1。

本文以电压信号作为输入,在 Pycharm 上建立了实数域多尺度与复数域多层次融合的定位方法。其中,初始学习率设置为 0.001,批量大小设置为 30,循环迭代训练周期为 30 次;为防止过拟合发生,添加 Dropout 层并设置随机失活率为 0.2;采用 Adam 自适应优化器,交叉熵函数作为目标函数训练模型。完成训练之后,选取最优模型在测试集上进行故障定位方法的性能测试。


2.2 消融实验

为证明本研究提出的电路复合故障定位方法的可行性和优越性,进行了 3 组消融实验。输入仿真数据,分别使用以下方法对电路进行故障定位,获得的混淆矩阵如图 9 所示。第 1 组是在本文方法的基础上去除复数域的多层次特征提取网络,只留下实数域的多尺度特征提取网络进行故障定位,混淆矩阵如图 9(a) 所示;第 2 组在本文方法的基础上去除实数域的多尺度特征提取网络,只留下复数域的多层次故障定位方法,混淆矩阵如图 9(b) 所示;第 3 组是在复数域的多层次故障定位方法的基础上去掉深、浅层特征融合模块,得到了基于复数域的 CCNN 故障定位方法,混淆矩阵如图 9(c) 所示;本研究混淆矩阵如图 9(d) 所示。




(a) 基于实数域的多尺度故障定位方法

(a) Multi-scale fault location method in real domain




(b) 基于复数域的多层次故障定位方法

(b) Multi-layer fault location method in complex domain



(c) 基于复数域的CCNN故障定位方法

(c) CCNN fault location method in complex domain



(d) 本研究方法

(d) Our method

图 9 消融实验

Fig. 9 Ablation experiments

图 9(a)可知,实数域的多尺度故障定位方法对标签 3 可以达到 100%识别率;根据图 9(b)可知,复数域的多层次故障定位方法对标签 3 的故障定位准确率为 0;对比图 9(b)与图 9(c)可知,复数域的多层次故障定位方法和基于复数域的 CCNN 故障定位方法都将标签 3 的故障识别成标签 4 的故障,但是复数域的多层次故障定位方法在加入深浅层特征融合模块后加深了这种误判,说明深浅层融合模块确实能够扩大不同故障特征之间的差异,增加故障定位的平均准确率,但也会加深错误分类程度。根据图 9(d)可知,本文方法对标签 3 的故障定位准确率达到 100%。可见本文定位方法在加入实数域的多尺度特征提取网络后,能够对复数域的多层次特征提取网络中存在的问题进行矫正。

本研究将一定数目的标签 4 识别成标签 0,大量的标签 8 识别成标签 1,由表 1 可知,两种错误定位的共同点在于当 C1 出现小于 80%标准值的错误时,若 C2 同时出现故障,错误定位将更严重。由敏感性可知,C1 敏感性比 C2 低一些,因此与 C1 有关的故障,其特征相对不突出,完全定位 C1 相关故障有难度。C2 的敏感性高于 C1,C2 出现故障对电路的输出影响远高于 C1。因此当 C2 出现故障时,本研究很难完全准确判断此时 C1 是否出现故障。这也是未来模型继续改进需要解决的问题。

根据图 9,计算出各组方法的平均准确率,如表 2 所示。本研究定位方法的平均准确率较实数域和复数域定位方法的平均准确率分别高出 6.67%、6.12%,说明复实域结合的故障定位方法能够显著提高定位准确率。较其他 3 种方法而言,本研究定位算法在 9 类故障中均有较高的定位准确率,只有标签 4 和 8 的识别准确率未达到 90%,其他标签识别准确率都达到 90%及以上,其中标签 2、3、6 和 7 的识别率达到 100%。

表 2 各类故障定位准确率

Table 2 The accuracy of various fault labels

%

故障标签	故障类型	故障定位方法			
		基于实数域的多尺度	基于复数域的多层次	复数卷积神经网络	本文方法
0	正常	82.5	92.5	85.0	100.0
1	C1 ↓	80.0	90.0	95.0	97.5
2	C1 ↑	90.0	100.0	90.0	100.0
3	C2 ↓	100.0	0.0	45.0	100.0
4	C2 ↑	80.0	100.0	100.0	85.0
5	C1 ↑ C2 ↑	65.0	100.0	95.0	90.0
6	C1 ↓ C2 ↓	100.0	100.0	75.0	100.0
7	C1 ↑ C2 ↓	97.5	100.0	90.0	100.0
8	C1 ↓ C2 ↑	82.5	100.0	100.0	65.0
平均准确率		86.39	86.84	86.11	93.06


2.3 对比实验

将本研究提出的算法与基于通道注意力机制的故障

定位方法^[8]、具有双重注意力机制的故障定位方法^[9]、基于多尺度核卷积神经网络的故障定位方法^[10]、时间频率卷积


神经网络故障定位方法^[16]相比较,得到的混淆矩阵分别如图10(a)~(d)所示,本研究方法的混淆矩阵如图9(d)所示。

文献[8]和[10]对9种故障的定位准确率比较相近,但都仅有一个故障的定位准确率达到100%,其他情况很少出现高准确率的定位;文献[9]在标签4、标签5的准确率极低;文献[16]对9种故障的定位准确率都较低,很难有效定位到故障器件。本研究方法的混淆矩阵与图10对比可知,本研究方法对故障定位的整体准确率高于以上对比




(a) 基于通道注意力机制的故障定位方法^[8]

(a) Fault location method with channel attention mechanism^[8]




(b) 具有双重注意力机制的故障定位方法^[9]

(b) Fault location method with dual attention mechanism^[9]



(c) 基于多尺度核卷积神经网络的故障定位方法^[10]

(c) Fault location method with multi-scale cnnc^[10]



(d) 时间-频率残差卷积神经网络的故障定位方法^[16]

(d) Fault location method with time-frequency residual cnnc^[16]

图10 混淆矩阵

Fig.10 Confusion matrix

方法,且对55%以上的故障可以实现100%定位,不存在极低的故障定位准确率。说明本研究方法能够对电路故障实现稳定的定位。

表3给出包括本研究方法在内的5种定位方法的准确率。可知,本研究所提出的方法的平均准确率明显高于其他4种方法。文献[8-10]中的定位方法仅将注意力机制插入到卷积神经网络中,增加了网络深度但并不能有效提高定位准确率,本研究方法利用两种注意力机制分别完成特征提取和特征增强,在保持网络深度不激增的基础上显著提高了定位准确率;与文献[16]相比,借鉴其实数域和复数域融合的思想,但本研究方法增加了多尺度和多层次特征提取模块,将故障定位的平均准确率提高了23.34%。结果表明本研究方法在模拟电路的复合故障定位中具有一定的先进性。

表3 方法结果比较

Table 3 Comparison of different methods

故障定位方法	故障种类	准确率 / %
基于通道注意力机制的故障定位方法 ^[8]	9	82.78
具有双重注意力机制的故障定位方法 ^[9]	9	77.50
基于多尺度卷积网络的故障定位方法 ^[10]	9	85.83
时间频率卷积神经网络故障定位方法 ^[16]	9	69.72
本研究提出的算法	9	93.06

2.4 测试实验

为了测试本研究算法在模拟电路故障定位中的实际效果,搭建了 Sallen-Key 滤波电路进行故障定位测试。如图11所示,测试装置包括示波器、电源、Sallen-Key 电路测试板和激励源。其中,激励源所产生的信号为频率1 kHz 交流正弦信号,Sallen-Key 滤波电路测试板可以更换 C1 和 C2,能够模拟9种类型的电路故障。




图 11 Sallen-Key 电路

Fig. 11 Sallen-Key circuit

利用示波器收集电路的输出信号,然后将数据分别输入到对比方法和本研究方法中,获得故障定位的平均准确率。4种方法的准确率如表4所示,与仿真实验相比,四种方法的准确率整体偏低,但是本研究提出的定位方法仍较其他的方法有较高的准确率。实物实验结果表明,在实际应用中本研究的故障定位方法具有可行性。

表 4 方法结果比较

Table 4 Comparison of different methods

故障定位方法	故障种类	准确率/%
基于通道注意力机制的故障定位网络 ^[8]	9	79.72
具有双重注意力机制的故障定位网络 ^[9]	9	77.50
基于多尺度卷积网络的故障定位网络 ^[10]	9	79.17
时间-频率残差卷积神经网络 ^[16]	9	66.94
本研究提出的算法	9	85.83

3 结 论

本研究针对模拟电路多个故障并发条件下的故障器件定位问题,提出了一种结合了实数域多尺度特征提取与复数域多层次特征融合的故障定位方法。在 Sallen-Key 滤波器电路的仿真实验和测试实验中,本文方法对电路复合故障定位的平均准确率达到85%以上,最高准确率为100%,说明其在故障定位中具有鲁棒性和泛化能力;对比实验表明本研究方法可以有效提升准确率,为复合电路故障定位研究提供了有效的解决方案。

针对复合故障器件定位中特征提取不完备、卷积网络的结构冗余和参数激增问题,本研究工作的创新点在于,在实数域利用多尺度卷积和双重注意力机制对故障特征进行提取和强化,主要利用时间注意力机制的池化并置操作保留数据特征,利用通道注意力机制的池化相加操作减少参数数量,在控制网络深度、减少计算量的前提下,实现实数域的特征提取。创新点还体现在复数域利用包含跳跃连接的复数卷积神经网络提取复数域中的数据特征,主要利用 CCNN 跨层级所产生的特征差异,构建两个深层次

特征融合结构,在保留了容易丢失的浅层信息基础上,通过深层和浅层特征的融合,实现复数域特征提取。

未来的研究工作中,可以针对不敏感器件的故障定位的问题进行研究,另外在实时性故障定位研究方面也可以开展相关工作。

参考文献

- [1] 李光升, 欧博, 石海滨. 现代模拟电路故障定位技术发展综述[J]. 计算机测量与控制, 2019, 27(5): 5-8.
LI G SH, OU B, SHI H B. Summary of development of modern diagnostic techniques of analog circuit fault [J]. Computer Measurement & Control, 2019, 27(5): 5-8.
- [2] 陈晓梅, 王行健, 蔡焯, 等. 基于 AVMD 和排列熵的 t 分邻域嵌入流形 HHO-SVM 模拟电路故障诊断方法[J]. 电子测量与仪器学, 2024, 38(6): 233-240.
CHEN X M, WANG X J, CAI Y, et al. Analog fault diagnosis method based on AVMD and t-SNE using HHO-SVM [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(6): 233-240.
- [3] 黄敬尧, 李雅恬, 程煜. 基于 PSO-RBF 和 PCA-PSO-PNN 的六脉冲整流器故障诊断研究[J]. 国外电子测量技术, 2022, 41(5): 165-172.
HUANG J Y, LI Y T, CHENG Y. Research on fault diagnosis of six-pulse rectifier based on PSO-RBF and PCA-PSO-PNN [J]. Foreign Electronic Measurement Technology, 2022, 41(5): 165-172.
- [4] 杨东儒, 魏建文, 林雄威, 等. 基于自注意力机制的深度学习方法模拟电路故障定位[J]. 仪器仪表学报, 2023, 44(3): 128-136.
YANG D R, WEI J W, LIN X W, et al. A fault diagnosis algorithm for analog circuits based on self-attention mechanism deep learning [J]. Chinese Journal of Scientific Instrument, 2023, 44(3): 128-136.
- [5] AN Z N, WU F, ZHANG C, et al. Deep learning-based composite fault diagnosis [J]. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 2023, 13(2): 572-581.
- [6] 廖剑, 黄洁, 戴邵武, 等. FRFT 域能量谱模拟电路故障特征提取方法[J]. 海军航空大学学报, 2022, 37(4): 311-319.
LIAO J, HUANG J, DAI SH W, et al. Fault feature extraction method of analog circuits based on frft domain energy spectrum [J]. Journal of Naval Aviation University, 2022, 37(4): 311-319.
- [7] 赵师兵, 张志明. 基于时域信号特征和卷积神经网络的模拟电路故障定位算法[J]. 计算机应用, 2022, 42(S2): 320-326.
ZHAO SH B, ZHANG ZH M. Fault diagnosis

- algorithm of analog circuits based on time domain signal features and convolutional neural network[J]. Journal of Computer Applications, 2022, 42 (S2): 320-326.
- [8] GAO J Y, GUO J, YUAN F, et al. An exploration into the fault diagnosis of analog circuits using enhanced golden eagle optimized 1d-convolutional neural network with a time-frequency domain input and attention mechanism [J]. Sensors, 2024, 24 (2): 1-20.
- [9] CHEN L, KHAN U S, KHATTAK M K, et al. An effective approach based on nonlinear spectrum and improved convolution neural network for analog circuit fault diagnosis[J]. Review of Scientific Instruments, 2023, 94(5).
- [10] SIVAPRIYA A, KALAIARASI N, VERMA R, et al. Fault diagnosis of cascaded multilevel inverter using multiscale kernel convolutional neural network[J]. IEEE Access, 2023.
- [11] WANG SH D, LIU ZH B, JIA ZH, et al. Intermittent fault diagnosis of analog circuit based on enhanced one-dimensional vision transformer and transfer learning strategy[J]. Engineering Applications of Artificial Intelligence, 2024, 127: 107281.
- [12] 王鹤, 吴国新, 刘秀丽. 基于 MADCNN 的故障诊断方法研究[J]. 电子测量与仪器学报, 2023, 37(3): 187-193.
- WANG G, WU G X, LIU X L. Research on fault diagnosis method based on MADCNN[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (3): 187-193.
- [13] CHEN Q, DAI X Y, SONG X J, et al. ITSC fault diagnosis for five phase permanent magnet motors by attention mechanisms and multi-scale convolutional residual network [J]. IEEE Transactions on Industrialelectronics, 2024, 71(8): 9737-9746.
- [14] TRABELSI C, BILANIUK O, ZHANG Y, et al. Deep complex networks [J]. ArXiv preprint arXiv: 1705.09792, 2017.
- [15] GAO T Y, YANG J L, JIANG SH D, et al. An incipient fault diagnosis method based on complex convolutional self-attention autoencoder for analog circuits [J]. IEEE Transactions on Industrial Electronics, 2023, DOI: 10.1109/TIE.2023.3310075.
- [16] WU CH X, JIANG R, WU X, et al. A time-frequency residual convolution neural network for the fault diagnosis of rolling bearings [J]. processes, 2024, 12(1): 1-26.

作者简介

宋佳宇, 硕士研究生, 主要研究方向为智能故障诊断方法。

E-mail: 2504545547@qq.com

高雪莲(通信作者), 副教授, 主要研究方向为人工智能在电力电子系统中的应用。

E-mail: xuelian_gao@ncepu.edu.cn