

DOI:10.19651/j.cnki.emt.1802137

# 基于时间卷积网络的模拟电路故障诊断方法

阳景 潘强 潘红兵

(海军工程大学 电子工程学院 武汉 430033)

**摘要:** 对模拟电路故障诊断中的故障特征提取进行了研究,引入了卷积神经网络模型,提出了一种基于时间卷积神经网络的模拟电路故障诊断方法,在四阶 Butterworth 低通滤波器电路上分别对不同深度的时间卷积网络进行分类对比实验,实验结果证实了深度时间卷积网络在故障特征提取中的有效性。同时设计实验对比了时间卷积神经网络、SAE-SOFTMAX、深度信念网络和长短期记忆网络的特征提取能力,结果表明,时间卷积神经网络模型在模拟电路故障诊断中能够提取出更能反映数据本质的特征,取得更好的诊断准确率。

**关键词:** 模拟电路;故障诊断;深度学习;卷积神经网络;特征提取

**中图分类号:** TN710 **文献标识码:** A **国家标准学科分类代码:** 510.1010

## Fault diagnosis method of analog circuits based on temporal CNN

Yang Jing Pan Qiang Pan Hongbing

(Electronic Engineering College, Naval University of Engineering, Wuhan 430033, China)

**Abstract:** In view of the feature extraction for analog circuit fault diagnosis, this paper introduces the convolutional neural network into this study field, and presents an analog circuit fault diagnosis method based on deep temporal convolutional neural network (TCN). Comparison experiments on a 4th-order Butterworth lowpass filter with a group of TCN with various depth prove that the model of deep TCN is effective in feature extraction of circuit fault. Moreover, comparison experiments with a group of models including TCN, SAE-SOFTMAX, deep belief network and long short-term memory network prove that the TCN based fault diagnosis method is more effective to extract features closed to essence of data, and capable to achieve a better accuracy in analog circuit fault diagnosis.

**Keywords:** analog circuit; fault diagnosis; deep learning; convolutional neural network; feature extraction

## 0 引言

模拟电路虽然只占电子设备电路的20%,但其单故障的出现概率则达到了80%以上。相比于数字电路的故障检测,模拟电路本身原件参数离散化、输入输出连续化等特点,给检测过程带来了诸多困难。目前模拟故障电路的特征提取方法主要有主成分分析(principal components analysis, PCA)<sup>[1]</sup>、小波分析<sup>[2]</sup>、小波包分析<sup>[3-4]</sup>、支持向量机(support vector machine, SVM)<sup>[5]</sup>、核分析<sup>[6]</sup>等。传统的分析方法由于有诸多的人为设定的超参数和基核的存在,优化方法与数据之间也往往无关,最后的分析结果受经验影响较大,很难对故障特征进行有效的提取。深度学习(deep learning, DL)近年来在图像、音频、文字等领域取得了极大的优势,通过反向传播算法<sup>[7]</sup>(back propagation, BP)能够对目标数据进行自动的参数化训练学习,往往能得到更有效的特征表达。近年来有学者将深度信念网

络(deep belief network, DBN)<sup>[8]</sup>、多层感知机(multilayer perceptron, MLP)等神经网络引入到故障诊断的领域中来,取得了很好的效果,然而深度学习中最为有效的卷积神经网络(convolutional neural network, CNN)<sup>[9]</sup>在模拟电路故障诊断中的应用几乎仍然是一片空白。本文提出一种基于时间卷积网络模型(temporal convolutional network, TCN)<sup>[10]</sup>的模拟电路故障诊断方法,并通过多个对比实验研究网络各部分的性能影响。实验证明,该网络可以更有效地进行故障特征提取。

## 1 卷积神经网络基本原理

### 1.1 卷积神经网络

卷积神经网络<sup>[9]</sup>是近些年逐步兴起的一种人工神经网络(artificial neural network, ANN)结构,其主要思想为多层次网络,局部连接以及权值共享,实现方式主要依靠卷积层(convolutional layer, Conv)、池化层(pooling layer,

Pool)、激活层 (activation layer, AL)、全连接层 (fully-connected layer, FC) 以及其他一些辅助层的级联。总体结构如图 1 所示。

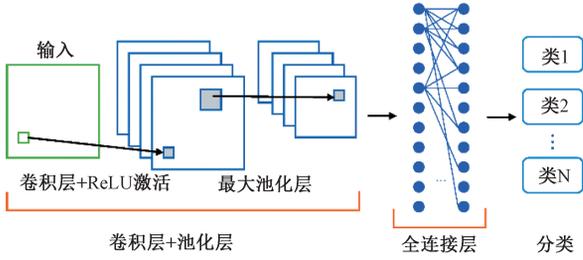


图 1 卷积神经网络

卷积层是 CNN 网络的核心,承担了网络大部分的计算任务,负责关联数据的特征提取,其中图像处理中的卷积层计算方式定义如下:

$$Y^l(m, n) = X^k(m, n) * H^{kl}(m, n) =$$

$$\sum_{k=0}^{K-1} \sum_{i=0}^{I-1} \sum_{j=0}^{J-1} X^k(m+i, n+j) H^{kl}(i, j) \quad (1)$$

式中: \* 代表卷积操作,假定卷积层有  $L$  个输出通道和  $K$  个输入通道,卷积核大小为  $I \cdot J$ 。其中  $X^k$  表示第  $k$  个输入通道的二维特征矩阵,  $Y^l$  表示第  $l$  个输出通道的二维特征矩阵,  $H^{kl}$  表示第  $k$  行、第  $l$  列的二维卷积核。卷积核的计算与传统的卷积运算不同,是对输入图片做滑动窗口的运算,通过参数减少和权值共享等方式,相比于传统 MLP 网络,极大减少了连接的个数与训练参数的个数,提高了网络的最大容量。

卷积层给网络带来了线性拟合能力,隐式地从训练数据进行学习,从而避免了显式地人工特征提取。为了提高网络的拟合能力,需要引入非线性层,常用的是非线性修正函数 (rectified linear unit, ReLU),函数表达式为:

$$\phi(x) = \max(0, x) \quad (2)$$

其在 0 附近具有非线性特性,而在其他位置保持线性,防止网络训练过程中的梯度消失问题。除此之外,通常会在连续的卷积层间插入池化层。池化层对卷积层提取的特征进行下采样来减少特征的维度大小,以此来减少参数数量与网络计算量,防止出现对数据的过拟合。常用的池化操作为对特征的每一个通道,在空间上使用带有步长的最大池化滤波器进行下采样。

CNN 最通常的结构是由卷积-激活层和池化层不断堆叠,直到提取出的特征维度达到合适的大小。构成模式为:  $INPUT \rightarrow [[CONV \rightarrow ReLU] * N \rightarrow POOL?] * M \rightarrow [FC \rightarrow ReLU] * K \rightarrow FC$ , 其中 \* 指重复堆叠, POOL? 指可选的池化层  $N, M, K$  分别表示不同网络层的重复次数, FC 表示全连接层。全连接层的主要任务有两部分: 1) 给网络提供全局特征,卷积层通过局部连接获得局部关联特征,而全连接层对这些特征进行全局的处理; 2) 进一步压缩获得的特征,以便分类器进行分类。从 CNN 中可以提取出两种不同的特征,一种是从全连接层得到的高维特

征;另一种则是从最后一层卷积层得到的低维特征,前者适合分类等全局视觉任务,后者则更适合于图像分割等像素级的视觉任务。

### 1.2 卷积神经网络的训练算法

CNN 在前向传播时,数据依次流过不同层,得到逐层输出,最后一层的输出与目标函数比较得到损失值,根据计算得到每一层的梯度更新值,对每层的参数进行更新,从而完成一次迭代。本文选取目标函数为交叉熵损失:

$$L(\theta) = - \sum_{i=1}^n y_i \cdot \log(\hat{y}_i) \quad (3)$$

式中:  $y_i$  表示真实概率分布;  $\hat{y}_i$  表示预测概率分布;那么交叉熵损失其实表示了预测概率分布和真实概率分布的相似程度。这里的概率分布使用 SoftMax 函数计算。

$$\hat{y}_i = e^{a_i} / \sum e^{a_i} \quad (4)$$

式中:  $a_i$  是输入到 SoftMax 层的上一层的输出值。对 SoftMax 函数进行求导:

$$\frac{\partial \hat{y}_i}{\partial a_i} = \begin{cases} \hat{y}_i(1 - \hat{y}_i), & i = j \\ -\hat{y}_i \hat{y}_j, & i \neq j \end{cases} \quad (5)$$

将 SoftMax 函数的求导代入到交叉熵损失中,可以得到 SoftMax 交叉熵最终的导数。

$$\frac{\partial L}{\partial a_i} = - \sum_j y_j \frac{1}{y_j} \cdot \frac{\partial \hat{y}_j}{\partial a_i} = \hat{y}_j - y_j \quad (6)$$

根据链式求导法则,由式(6)可以得到每一个网络层参数的误差修正值。通过不断地对各个参数进行修正,网络最后达到收敛。

小批量梯度下降法训练算法 (mini-batch gradient descent, MBGD)<sup>[11]</sup>如下所示:

输入:训练数据集  $D$ , 网络模型,批量大小  $m$ , 最大训练周期  $T$ , 学习率  $\alpha$ 。

输出:卷积层的参数  $W$ , 偏置  $b$ 。

初始化:  $W$  使用 Xavier 初始化<sup>[12]</sup>,  $b$  初始化为 0; 随机将数据集  $D$  分为  $D = \{D_1, D_2, \dots, D_N\}$ , 其中每一份数量为  $m$ 。

For  $t = 1, 2, \dots, T$

For  $n = 1, 2, \dots, N$

将  $D_n$  输入到  $M$ , 得到预测概率分布  $\hat{y}_i$ ;

根据式(6)得到 SoftMax 交叉熵最终的导数;

由链式求导法则,计算每一个网络层的更新值;更新网络参数:

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \alpha \frac{\partial}{\partial W_{ij}^{(l)}} J(W, b) \quad (7)$$

$$b_i^{(l)} = b_i^{(l)} - \alpha \frac{\partial}{\partial b_i^{(l)}} J(W, b) \quad (8)$$

End for

End for

## 2 模拟电路故障诊断网络设计

### 2.1 仿真电路与数据采集

本文选用四阶 Butterworth 低通滤波器电路,电路结构如图 2 所示,电路元件的正常参数是  $R_1 = 10 \text{ k}\Omega, R_2 = 12.53 \text{ k}\Omega, R_5 = 100 \text{ k}\Omega, R_6 = 15.2 \text{ k}\Omega, R_3 = R_4 = R_7 = R_8 = 1.6 \text{ k}\Omega, C_1 = C_2 = C_3 = C_4 = 0.1 \mu\text{F}$ 。运放的直流激励为  $V_{DD} = +15 \text{ V}, V_{EE} = -15 \text{ V}$ 。仿真中设置电阻 5% 高斯容差漂移,电容 10% 高斯容差漂移。根据图 2 所示实验电路,设置单故障集 {正常,  $R_{20}, R_{2s}, R_2 \uparrow, R_2 \downarrow, R_{30}, R_{3s}, R_3 \uparrow, R_3 \downarrow, R_{80}, R_{8s}, R_8 \uparrow, R_8 \downarrow, C_{10}, C_{1s}, C_1 \uparrow, C_1 \downarrow, C_{40}, C_{4s}, C_4 \uparrow, C_4 \downarrow$ }, 共 21 种不同情况,其中  $\uparrow$  和  $\downarrow$  分别表示上偏 50% 和下偏 50%;  $O$  表示开路元件,用  $200 \text{ M}\Omega$  电阻代替;  $S$  表示短路元件,用  $0.000 01 \Omega$  的电阻代替。对 21 种故障模式进行编号,根据故障集的顺序分别对应于 0~20 的标签值。

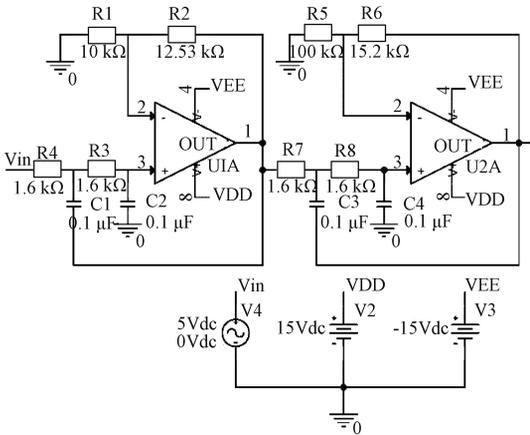


图 2 四阶 Butterworth 低通滤波器电路

在仿真电路中设置激励源为频率 600 Hz,幅度为 5 V 的交流信号。对每一类故障模式均做 300 次蒙特卡洛 (Monte-Carlo) 分析,每个周期采样 128 次,这样对于每次分析可以得到 128 维的电压时序向量样本和 1 个故障种类标量标签,总共获得 6 300 个样本。

### 2.2 网络设计

模拟电路故障数据是一维的向量,并且带有时间序列信息,这就导致作用在三维图像数据的传统卷积神经网络无法处理。本文引入时间卷积网络来进行序列建模,网络结构如图 3 所示。本文 TCN 相较于传统卷积网络有如下特点。

1) TCN 使用一维扩张卷积 (dilated convolutions,  $T\_Conv$ )<sup>[13]</sup>。对于一维的序列输入  $x \in \mathbb{R}^n$ , 记 1-维滤波器  $f: \{0, \dots, k-1\} \rightarrow \mathbb{R}$ , 其计算表达式为:

$$F(s) = (x * {}_d f)(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \quad (9)$$

式中:  $d$  指扩张系数;  $k$  为滤波器大小。因此扩张卷积相当于在卷积核中引入一定的步长,这样保证了处理时序数据时每一层的隐层输出大小和输入序列大小相同,并且降低计算量,扩大了感受野。

2) 时序特征的提取要求对时刻  $t$  预测只能通过  $t$  时刻之前的输入,这在 CNN 中被称为因果卷积 (causal convolutions,  $C\_Conv$ )<sup>[14]</sup>。在 TCN 中,通过对扩张卷积的窗口滑动限制(调整每一层网络的扩张系数和边缘填充)来实现。

3) 为了提高准确度,TCN 中加入了残差卷积<sup>[15]</sup>的恒等映射,即将第  $n$  层网络的输入通过一个  $1 \times 1$  的卷积层后叠加到第  $n+1$  层网络的输出上。

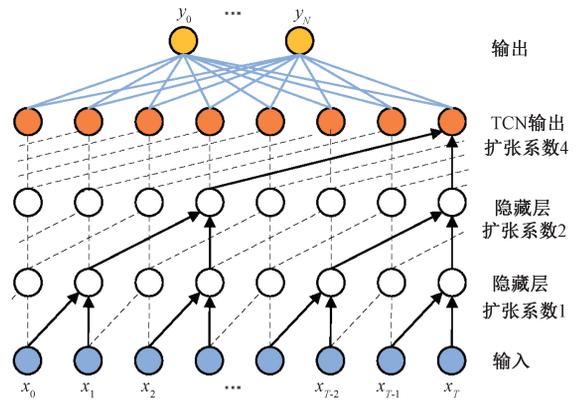


图 3 时间卷积网络

针对模拟电路故障诊断任务设计的网络结构为  $INPUT \rightarrow [T\_CONV \rightarrow Padding \rightarrow ReLU] * N * M \rightarrow [FC \rightarrow ReLU] * K \rightarrow FC$ , 其中  $*$  表示层的堆叠,  $Padding$  表示对输出特征的前向补零操作。

## 3 实验结果与讨论

本文的实验均是在搭载 Intel E5-2670 8 核 CPU,主频 2.6 GHz,内存 32 GB,显卡 Titan xp,安装 Ubuntu 16.04 操作系统的服务器上进行,实验电路在 OrCAD 中进行仿真和数据收集,实验网络使用 Pytorch 框架编写和运行。

### 3.1 数据处理与实验设置

在 2.1 节通过对仿真电路的蒙特卡洛分析,对 21 种故障模式中的每一个故障模式均可获得 300 个样本。其中实验电路的正常情况下的幅频响应如图 4 所示。模拟电路激励的幅值随着不同应用场景而发生变化。为了得到鲁棒的网络模型,在实验中输入到模拟电路故障诊断网络前,需要首先对数据样本进行归一化处理,将之映射到  $[0, 1]$  区间内。采用的归一化公式为  $x = (x - \eta_x) / \sigma_x$ , 其中  $\eta_x$  表示输入的均值;  $\sigma_x$  表示输入的标准差。在实验中,采用 6-折交叉验证法,即将所有的数据样本按照故障模式随机分为 6 份,每次选取 5 份(每个故障模式 250 个样本,总计 5 250 个

样本)作为训练集,剩余 1 份(每个故障模式 50 个样本,总计 1 050 个样本)作为测试集,总计实验 6 次,最终结果选取 6 次实验的均值。

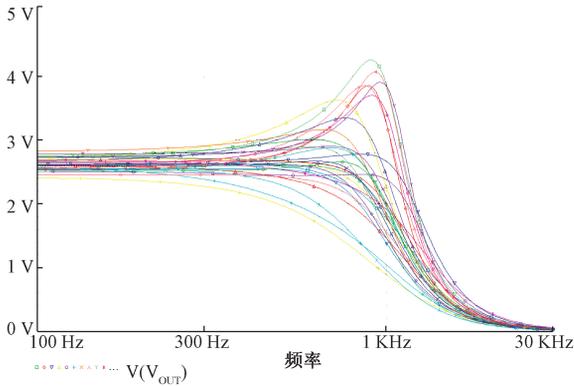


图 4 正常模式下 30 次 Monte-Carlo 分析的幅频响应

网络的扩张卷积层的节点数均为 128,和输入维度一致。卷积层之后的全连接层的节点依旧保持 128 维。最后一层全连接层的节点数降为 21,和故障集类别数量一致。设计网络层数时,固定  $N = 2$ ,而分别取  $M = \{1, 3, 5, 7\}$  和  $K = \{1, 2, 3\}$  的组合共计 12 种情况进行分别实验。实验中设置每个批量大小  $m = 16$ ,最大训练周期  $T = 100$ ,学习率  $\alpha = 4$ ,并且设置学习率每 5 个训练周期降为原来的 0.1。训练过程中使用梯度裁剪方法,当计算出的每一层的误差更新值大于 0.15,超出的部分会被截断,防止发生梯度爆炸。

### 3.2 网络设计对比实验

对于不同深度的时间卷积神经网络进行对比实验,在网络参数分别选择  $M = \{1, 3, 5, 7\}$  和  $K = \{1, 2, 3\}$  时获得的实验结果如表 1 所示。

表 1 不同网络参数的对比实验结果 (%)

$K \setminus M$	1	3	5	7
1	93.6	97.5	96.6	95.2
2	94.8	97.2	96.4	95.3
3	94.4	96.5	95.3	94.7

由表 1 可得,在网络参数选择为  $M = 3, K = 1$  时,对于本文采集的数据,时间卷积网络模型达到了最高的准确率,此时网络的 6-折交叉验证的所有准确率如表 2 所示。由表 2 可得网络对于故障诊断的准确率可以达到  $97.5 \pm 0.7\%$ 。对于不同取样方式,准确度的偏差小于  $0.7\%$ ,表明网络具有一定的鲁棒性。

### 3.3 特征提取性能评估

为了证明本文提出的时间卷积神经网络在模拟电路故障诊断特征提取任务中的有效性,实验选用了 4 种常用的故障诊断方法来进行对比实验。其中直接非循环图支持向

表 2 十折交叉验证的预测准确率 (%)

6-折交叉验证	诊断准确率
交叉验证 1	97.3
交叉验证 2	96.8
交叉验证 3	97.4
交叉验证 4	98.1
交叉验证 5	97.2
交叉验证 6	98.2

量机(directed acyclic graph-support vector machine, DAG-SVM),自编码分类器(stacked auto-encoder softmax classifier, SAE-SOFTMAX),DBN,以及同样基于时序信息的长短期记忆网络(long short-term memory, LSTM)。所有实验均使用 6-折交叉验证法进行实验。前 3 种方法使用小波包能量熵<sup>[4]</sup>的方法对输入数据进行处理,后一种的输入和本文 TCN 处理方法一致。SAE-SOFTMAX 中 SAE 网络采用 128-4-21 的网络结构,DBN 中采用 128-100-21 的网络结构。LSTM 采用 2 层隐层,每层节点数量为 128。几种方法的对比实验结果如表 3 所示。

表 3 5 种模拟电路故障诊断方法对比

方法	诊断准确度/%	网络参数量/k
DAG-SVM	92.7	—
SAE-SOFTMAX	95.3	29
DBN	95.8	43
LSTM	93.6	35
TCN	97.5	19

观察表 3 的诊断准确度,本文提出的 TCN 故障诊断法在仅使用原始输出电压数据的情况下就取得了几种算法中的最好准确度,表明了 TCN 的故障诊断电路特征提取能力较强。同时 TCN 算法在几个算法中参数量较小,对设备的要求较低,利于部署使用。相较于同样处理时序信息的 LSTM 网络,本文的 TCN 算法在准确率上超出了 3.9%。

为了观察 TCN 网络对于模拟电路故障特征提取的有效性,本文选取了网络参数为  $M = 3, K = 1$  时交叉验证 3 的实验模型,对剩余的 1 050 个测试样本进行诊断,将网络倒数第 2 层全连接层输出的特征进行保存,并通过 PCA 法映射到二维空间,得到二维特征分布如图 5 所示。从图中可以看出,经过网络的前向传播计算,得出的特征根据不同的故障模式有明显的区分度。但是仍然存在几组不易区分的故障,比如故障 0,4;故障 6,10,12,15 和故障 2,7 等。对实验进一步分析可知,出现分类错误的故障恰恰是这几类。

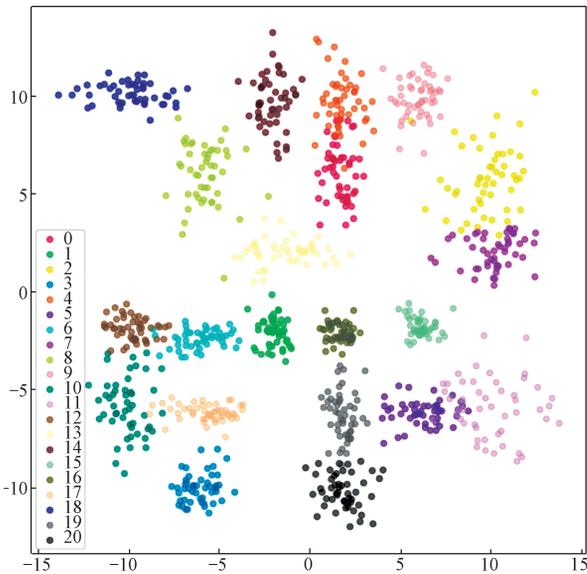


图 5 故障特征的 PCA 可视化

## 4 结 论

本文将 TCN 应用于模拟电路故障诊断领域,通过设计实验,在四阶 Butterworth 低通滤波器仿真电路上对比了不同的结构参数的 TCN 网络模型,验证了 TCN 网络在模拟电路故障特征提取任务中的有效性。对比了 SAE-SOFTMAX、DAG-SVM、DBN、LSTM 等方法,结果表明,深度时间卷积神经网络提取的特征更能反映数据的本质,特征提取能力优于其他几种方法。另外,本研究中仅使用输出电压波形作为输入数据,后期研究可以进一步对数据进行小波包等处理,或者增加数据采样点和采样种类,以使得算法具有更高的诊断精度及更广的适用性。

## 参考文献

- [1] 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.
- [2] 韩宝如,孟玲玲. 一种基于小波神经网络的模拟电路故障诊断方法[J]. 电子测量技术, 2006(6): 14-16, 18.
- [3] 袁莉芬,孙业胜,何怡刚,等. 基于小波包优选的模拟电路故障特征提取方法[J]. 电工技术学报, 2018, 33(1): 158-165.
- [4] 肖玉飞,刘祖润,李目. 基于小波包能量熵与 SVM 的模拟电路故障诊断[J]. 电子测量技术, 2011, 34(6): 110-113.
- [5] 吕洪爽,何玉珠. 基于 CBA-SVM 的模拟电路故障诊断

方法研究[J]. 电子测量技术, 2018, 41(7): 6-10.

- [6] 伞冶,石慧妹,郭珂. 核方法及其在模拟电路故障诊断中的研究进展[J]. 电子测量技术, 2013, 36(1): 91-96.
- [7] 陈冰,尹禄,梁伟锋. 基于 BP 网络的容差模拟电路故障诊断研究[J]. 电子测量技术, 2007, 30(5): 61-63.
- [8] 颜学龙,邵伟. 深度信念网在模拟电路故障诊断中的应用研究[J]. 微电子学与计算机, 2016, 33(9): 159-163.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [C]. Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [10] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J]. 2018, arXiv preprint arXiv:1803.01271.
- [11] LI M, ZHANG T, CHEN Y, et al. Efficient mini-batch training for stochastic optimization [C]. Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2014: 661-670.
- [12] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [C]. Proceedings of the 13th International Conference on Artificial Intelligence and Statistics, 2010: 249-256.
- [13] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [J]. 2015, arXiv preprint arXiv:1511.07122.
- [14] VAN DEN OORD A, DIELEMAN S, ZEN H, et al. WaveNet: A generative model for raw audio [C]. SSW 2016: 125.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

## 作者简介

**阳景**, 硕士研究生, 主要研究方向为电路与系统、电路故障诊断。

E-mail: yangvsjing@126.com

**潘强**(通信作者), 副教授、硕士生导师, 主要从事信号检测与处理等方向研究和电子技术教学工作。

E-mail: panqhjgc@163.com

**潘红兵**, 副教授、硕士生导师, 主要从事信号检测与处理等方向研究和电子技术教学工作。

E-mail: 413522104@qq.com