

# 控制与决策

Control and Decision

## 基于CBAM-CNN的模拟电路故障诊断

杜先君, 巩彬, 余萍, 石耀科, AngelinaKuzina V., 程生毅

引用本文:

杜先君, 巩彬, 余萍, 石耀科, AngelinaKuzina V., 程生毅. 基于CBAM-CNN的模拟电路故障诊断[J]. 控制与决策, 2022, 37(10): 2609-2618.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1111>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于W-DenseNet的减压阀不平衡样本故障诊断模型

W-DenseNet-based fault diagnosis model of pressure-reducing valve with unbalanced samples  
控制与决策. 2022, 37(6): 1513-1520 <https://doi.org/10.13195/j.kzyjc.2020.1708>

#### 基于径向基神经网络的新型齿轮故障诊断方法

Novel gear fault diagnosis method based on RBF neural network  
控制与决策. 2022, 37(2): 409-416 <https://doi.org/10.13195/j.kzyjc.2020.0836>

#### 基于三端注意力机制的视网膜血管分割算法

Improved U-Net based on three-terminal attention mechanism for retinal vessel segmentation  
控制与决策. 2022, 37(10): 2505-2512 <https://doi.org/10.13195/j.kzyjc.2021.0435>

#### 融合注意力机制的域泛化行人再识别

Domain generalization person re-identification based on attention mechanism  
控制与决策. 2022, 37(7): 1721-1728 <https://doi.org/10.13195/j.kzyjc.2020.1844>

#### 改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis  
控制与决策. 2021, 36(1): 135-142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

# 基于CBAM-CNN的模拟电路故障诊断

杜先君<sup>1,2†</sup>, 巩彬<sup>1</sup>, 余萍<sup>1,2</sup>, 石耀科<sup>1</sup>, Kuzina V. Angelina<sup>1</sup>, 程生毅<sup>1,2</sup>

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050;

2. 兰州理工大学 甘肃省工业过程先进控制重点实验室, 兰州 730050)

**摘要:** 针对模拟电路的故障特征难以提取, 导致模型计算量复杂、诊断准确率不够高的问题, 提出一种基于注意力机制和卷积神经网络(CBAM-CNN)的模拟电路故障诊断方法. 首先, 利用卷积核提取输入层的图片特征, 同时每个卷积层后面连接一个矫正线性单元(ReLU), 并添加批归一化层(BN)解决内部协变量偏移的问题, 以提高非线性模型表达能力; 然后, 在批归一化层后添加注意力机制模块(CBAM), 提取重要的特征后连接池化层, 降低网络计算复杂度, 提高网络的准确率与效率; 最后, 以Sallen-Key低通滤波器和二级四运放双二阶低通滤波器为研究对象进行故障诊断实验验证. 结果表明, 所提出方法能够有效提升诊断精度, 实现所有故障的高难分类与定位.

**关键词:** 模拟电路; 卷积神经网络; 注意力机制; 特征提取; 故障诊断

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1111

开放科学(资源服务)标识码(OSID):



引用格式: 杜先君, 巩彬, 余萍, 等. 基于CBAM-CNN的模拟电路故障诊断[J]. 控制与决策, 2022, 37(10): 2609-2618.

## CBAM-CNN based analog circuit fault diagnosis

DU Xian-jun<sup>1,2†</sup>, GONG Bin<sup>1</sup>, YU Ping<sup>1,2</sup>, SHI Yao-ke<sup>1</sup>, Kuzina V. Angelina<sup>1</sup>, CHENG Sheng-yi<sup>1,2</sup>

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;

2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** The difficulty in extracting the fault features of analog circuits leads to complex calculation and poor precision with the model. A fault diagnosis method for analog circuits based on the attention mechanism and the convolutional neural network (CBAM-CNN) is proposed. Firstly, the image features of the input layer are extracted by using the convolution kernel, and a rectifying linear unit (ReLU) is connected behind each convolution layer, and a batch normalization (BN) layer is added to solve the problem of internal covariate migration, so as to improve the expression ability of the nonlinear model. Secondly, the convolutional block attention module (CBAM) is added after the batch normalization layer to extract the important features. After that, the pooling layer is connected to reduce the computational complexity of the network and improve the accuracy and efficiency of the network. Finally, the Sallen-Key low-pass filter and the two-stage four-op amplifier double-order low-pass filter are taken as the research objects. The results of fault diagnosis experiments demonstrate that the proposed method can effectively improve the diagnosis accuracy and realize the classification and location of all faults with high difficulty.

**Keywords:** analog circuit; convolutional neural network; attention mechanism; feature extraction; fault diagnosis

## 0 引言

随着模拟电路广泛应用于国防、军事、航天等重要领域, 模拟电路故障诊断技术逐步成为电路测试领域的研究热点<sup>[1]</sup>. 据统计数据表明, 模拟电路故障时元器件的故障率超过 80%. 模拟电路作为电子系统组成的基础, 对元器件故障的准确诊断是确保电子系统稳定运行的重要前提<sup>[2-10]</sup>. 但是, 由于电路本身的非线性、容差性等因素, 模拟电路故障诊断技

术发展缓慢, 在生产、生活中无法发挥实际作用. 针对模拟电路故障诊断这一课题, 国内外学者对其展开了相应研究<sup>[11-13]</sup>. 小波变换等信号处理方法在非线性和系统故障特征提取与诊断中得到广泛应用<sup>[14-16]</sup>, 但在特征提取的过程中容易忽略本质特征, 导致非线性模拟电路故障诊断的效率和准确率过低<sup>[10,17]</sup>. 为了解决该问题, BP神经网络、支持向量机(support vector machine, SVM)、极限学习机(extreme learning

收稿日期: 2021-06-26; 录用日期: 2021-10-27.

基金项目: 国家自然科学基金项目(61963025); 甘肃省教育厅: 优秀研究生“创新之星”项目(2021CXZX-499); 甘肃省高等学校创新基金项目(2021A-027).

†通讯作者. E-mail: xdu@lut.edu.cn.

machine, ELM)等人工智能方法广泛进入研究领域. 王力等<sup>[18]</sup>提出利用免疫遗传算法(immune genetic algorithm, IGA)优化BP反向传播中参数寻优过程,解决了BP神经网络陷入局部最小的问题;Zhang等<sup>[19]</sup>利用差分进化(differential evolution, DE)算法优化模型参数,提出DE-ELM模型,提高了故障诊断的准确度;Gu等<sup>[20]</sup>利用果蝇优化算法(fruit fly optimization algorithm, FOA)开发了一种新的基于半径裕的SVM方法(FOA-F-SVM),能够显著降低计算量,提高分类精度. 基于人工神经网络和支持向量机的分类器属于浅层学习模型,仍不能彻底揭示故障根源与信号特征之间复杂的内在关系<sup>[21]</sup>.

近年来,深度学习以其强大的学习能力和特征提取能力在故障诊断领域中广泛应用<sup>[22-23]</sup>. 在模拟电路故障诊断领域应用中,Zhao等<sup>[24]</sup>提出一种基于深度置信网络(deep belief nets, DBN)的模拟电路故障诊断方法. 从原始时间序列信号中自适应地提取特征,增加了灵活性,仿真结果表明了该方法在模拟电路诊断中的有效性. 典型的DBN模型<sup>[25-26]</sup>其结构参数由学习率确定,Zhang等<sup>[27]</sup>提出利用粒子群优化算法(particle swarm optimization, PSO)优化DBN学习率,再利用SVM进行故障诊断,有效提高了诊断精度. Liu等<sup>[28]</sup>提出的高斯-伯努利深度置信网络(GB-DBN)可以更有效地捕捉原始输出信号中的高阶语义特征,使诊断结果更加精确. 深度学习模型需要大量数据优化参数,容易出现过拟合现象<sup>[21,29-30]</sup>. He等<sup>[21]</sup>提出的基于生成对抗网络(generative adversarial network, GAN)的模拟电路故障诊断方法,可以在一定程度上消除过拟合现象. 另外,Du等<sup>[31]</sup>提出一种基于优化卷积神经网络(convolutional neural networks, CNN)的模拟电路故障诊断方法,简化了诊断过程,提高了故障诊断效率和性能. Yang等<sup>[32]</sup>利用一维卷积神经网络(1D-CNN)实现了四阶Butterworth低通滤波器电路的故障诊断,并证明其具有更好的抗干扰性能以及较高的实际应用价值. Shokrolahi等<sup>[33]</sup>提出的基于CNN的模拟电路故障诊断方法,使用故障信号功率谱密度的实部作为CNN的输入图像,实现准确诊断的同时验证了CNN网络在该类问题中应用的优越性. 阳景等<sup>[34]</sup>提出了一种基于时间卷积神经网络(temporal convolutional neural networks, TCN)的模拟电路故障诊断方法,实验证明,TCN能够有效提取数据本质的特征,提高模拟电路故障诊断准确性. Zhang等<sup>[35]</sup>采用后向差分策略对数据进行处理,并引入了一种具有

全局平均池化(global average pooling, GAP)的卷积神经网络(CNN-GAP)进行特征提取和故障分类,实验结果表明,该方法在诊断准确率和可靠性方面具有优势. Liu等<sup>[36]</sup>开发了一个基于错位时间序列的CNN诊断框架,改善了CNN在工业故障诊断效果不佳的问题. Pan等<sup>[37]</sup>提出一种新的深度学习网络(Lifting Net),可在没有先验知识的前提下,自适应地从原始机械数据中学习特征,并且改善了数据集在CNN中要求转速一致的局限性. Wang等<sup>[38]</sup>提出了一种基于小波包分解(wavelet packet decomposition, WPD)和双层卷积神经网络(bilayer convolutional neural network, biCNN)的非平衡数据条件下的故障检测模型. WPD从采集的故障样本中获得更丰富的各种时间和频率尺度的信息,有助于解决数据不平衡问题;改进的biCNN结合局部和全卷积阶段,用于特征提取和故障检测. 此外,由于CNN无法自主选择重要通道,基于注意力机制的模型成功改善了该问题. 从squeeze and excitation networks (SENet)到selective kernel networks (SKNet)再到convolutional block attention module (CBAM)<sup>[39-41]</sup>,都在不同程度上优化了CNN. 张红斌等<sup>[42]</sup>利用SENet中具有良好互补性的异构层特征,实现异构层特征融合,提高了正确率. Fu等<sup>[43]</sup>在YOLOv4中添加CBAM模块,并验证了改进算法的有效性.

针对深度学习故障诊断方法容易出现过拟合、特征提取不合理等问题,本文构建基于CNN与CBAM相结合的模型用于模拟电路的故障诊断. 首先,在卷积层和池化层之间引入BN层,降低过拟合,加速收敛;然后,在BN层后加入CBAM模块,选择重要特征;最后,以Sallen-Key滤波器和二级四运放双二阶低通滤波器的故障诊断为例,验证CBAM-CNN模型的诊断性能与泛化性能.

## 1 CBAM-CNN

### 1.1 CNN

CNN于1998年由Yann LeCun提出,用于手写体数字识别<sup>[44]</sup>,其基本结构由卷积层、池化层、激活层、全连接层进行级联. 从数学上讲,卷积是一种数学运算,其数学表达式为

$$(f * g) = \int f(u)g(x-u)du, \quad (1)$$

或

$$f(n) * g(n) = \sum_{-\infty}^{\infty} f(m)g(n-m). \quad (2)$$

卷积层则应用了卷积的离散表示,计算式为

$$X_j^l = f\left(\sum_{i \in M_j^l} X_i^{l-1} * K_{ij}^l + B_j^l\right). \quad (3)$$

其中:  $f$  为激活函数,  $l$  为网络的层数,  $K$  为卷积核,  $M_j^l$  为层中特征映射的索引向量,  $B_j^l$  为第  $l$  层第  $j$  个单元的偏置. 卷积神经网络的样本集由向量对组成, 训练前需对权值进行初始化. CNN 的训练过程分为两个阶段:

1) 前向传播. 得到相应的实际输出  $O_p$ , 有

$$O_p = F_n(\dots(F_N(F_1(XW_1)W_2)\dots)W_n). \quad (4)$$

2) 反向传播(误差传播). 计算实际输出与理想输出的差异  $Y_p$ , 有

$$Y_p = \frac{1}{2} \sum_j (Y_{pj} - O_{pj})^2. \quad (5)$$

基于极小化误差的方法反向传播调整权值矩阵. 卷积神经网络所采用的局部连接和共享权值的方式, 一方面减少权值数量使网络易于优化, 另一方面降低过拟合风险.




图 1 CNN 典型结构

### 1.2 BN 层

为降低过拟合风险, 提高模型的训练速度. 在卷积层后添加批归一化层(batch normalization, BN). 基于规范化, 将每层神经网络任意神经元的输入值分布强制规范化为均值为 0、方差为 1 的标准正态分布, 使激活输入值落在非线性函数对输入比较敏感的区域, 从而得到较大的梯度, 避免梯度消失. 在 BN 层中引入学习参数  $\gamma$  和  $\beta$  对归一化以后的值进行变换重构, 即

$$Y(k) = \gamma(k)\hat{x}(k) + \beta(k). \quad (6)$$

每个神经元都会有参数  $\gamma$  和  $\beta$ , 当

$$\gamma^{(k)} = \sqrt{\text{Var}[x^{(k)}]}, \quad (7)$$

$$\beta^{(k)} = E[x^{(k)}] \quad (8)$$

时, 根据归一化方式  $\hat{x}^{(k)} = \frac{x^{(k)} - E[x^{(k)}]}{\sqrt{\text{Var}[x^{(k)}]}}$ , 代入式(6)化简, 最后可得

$$\gamma^{(k)} = x^{(k)}. \quad (9)$$

由式(6)~(9)可知, 引入学习参数  $\gamma$  和  $\beta$  时, 可以恢复某一层所学习到的特征. 所以在 BN 层中引入学习重

构参数  $\gamma$  和  $\beta$ , 从而恢复出原始网络所要学习的特征分布. BN 层前向传导过程如下.

step 1: 计算样本均值

$$\mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i.$$

step 2: 计算样本方差

$$\sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2.$$

step 3: 样本数据标准化处理

$$\hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}},$$

其中  $\epsilon$  为初始化参数值, 防止分母为 0.

step 4: 进行平移和缩放处理

$$y_i \leftarrow \gamma \hat{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i).$$

### 1.3 CBAM

精准提取故障特征是提高故障诊断准确率的前提. 卷积神经网络的卷积池化中默认特征图(feature map, FM) 的每个通道是同等重要的, 但由于所承载的信息重要性不同, 认定通道重要性相同缺乏合理性. 卷积注意力模块 CBAM 以人类视觉系统的处理机制为原理, 忽略不重要因素, 将所有注意力放在重要区域, 以此提高分类准确率. 具体做法是, 给每个信息分配不同的权重, 权重越大则信息越重要. CBAM 结构如图 2 所示, 包含两个独立的子模块: 通道注意力模块(channel attention module, CAM) 和空间注意力模块(spatial attention module, SAM). 与 SENet 相比, CBAM 在通道注意力模块 CAM 中添加了并行全局最大池化(global max pooling, GMP) 以及空间注意力 SAM 模块, 这样获得的信息会更加全面, 信息重要程度的分配也会更加合理, 对后续提高诊断精度有较大帮助.

图 3 为通道注意力模块 CAM 典型结构, 输入的特征图通过全局最大池化 GMP 和全局平均池化 GAP 得到对应的特征图; 然后通过多层感知器(multi-layer perception, MLP) 得到两个特征向量, 再将两个特征向量的元素逐个相加累积, 通过激活操作输出通道注意力特征, 并与最初的特征图进行相乘, 进行自适应特征细化; 最后得到新的特征图, 记为  $F'$ .

图 4 为空间注意力模块 SAM 典型结构. 将上述新的特征图( $F'$ ) 进行全局最大池化 GMP 和全局平均池化 GAP, 得到两个特征图. 拼接两个特征图通道, 经过卷积核为  $7 \times 7$  的卷积运算及激活操作, 将所得结果与输入的特征图相乘, 最终得到所需特征.




图2 CBAM结构




图3 通道注意力模块




图4 空间注意力模块

### 1.4 CBAM-CNN

本文CBAM-CNN是对CNN网络进行的有效改进。CBAM-CNN包括输入层、卷积层、修正线性单元(ReLU)、BN层、CBAM、池化层和全连接层,如图5所示。在卷积层与池化层之间加入BN层,并在每个BN

层后面加入CBAM模块。卷积层提取输入的不同特征;ReLU增加网络稀疏性,缓和过拟合;BN层提高训练速度,降低过拟合风险;CBAM模块提取重要特征,

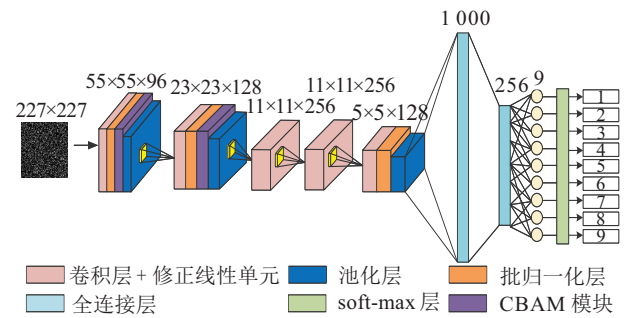


图5 CBAM-CNN模型

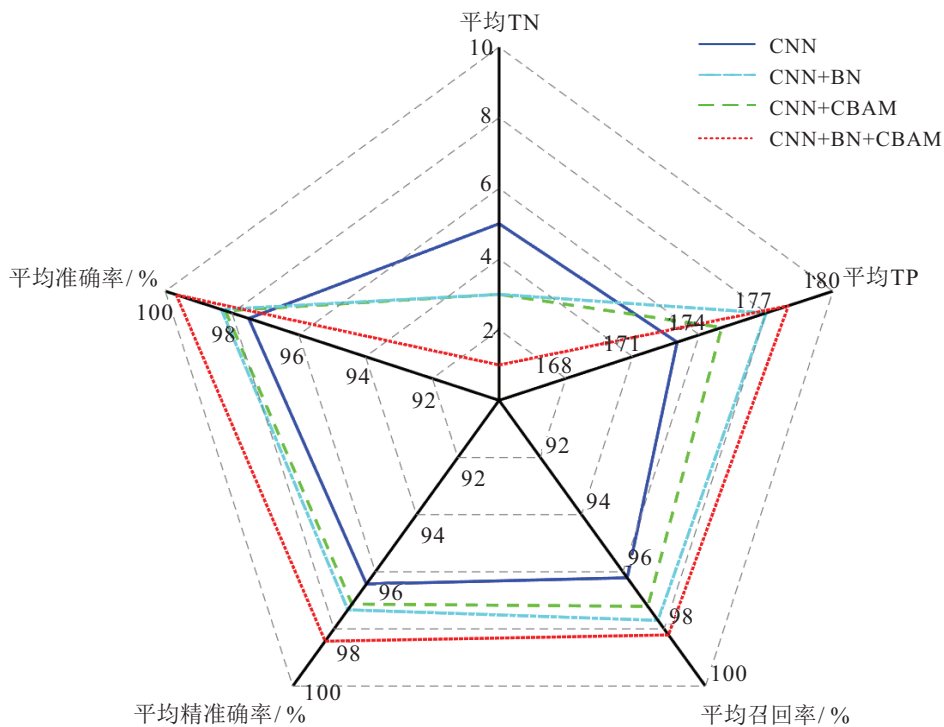


图6 消融实验性能对比结果

池化层降低模型参数量,优化工作量;全连接层连接所有特征,将输出值送入分类器进行分类. 在 Sallen-Key 数据集下的消融实验结果如图6所示,分别验证了 CNN、CNN+BN、CNN+CBAM、CNN+BN+CBAM 四种模型在平均准确率、平均精确率、平均召回率、平均TN、平均TP 五种指标的对比结果. 其中: TN 表示预测的故障编码与真实故障编码不一致, TP 表示预测的故障编码与真实故障编码一致.

由图6可见, BN 层和 CBAM 模块的增加在 5 个性能指标上均有不同程度的提升,验证了本文 CBAM-CNN 模型的有效性.

## 2 基于CBAM-CNN的模拟电路故障诊断

### 2.1 实验对象

针对电路中元器件易受噪声、温度等环境影响,从而可能偏离正常容差范围的问题,本文实验以 Sallen-Key 低通滤波器(图7)和二级四运放双二阶低通滤波器(图8)的典型电路为对象,将二者中可能存在的元器件,如电容、电感、电阻中存在偏大或偏小的问题进行准确分类定位.

### 2.2 故障类型定义及故障数据获取处理

增强机器学习模型泛化能力最好的办法是使用更多样的训练样本<sup>[45]</sup>. 本文利用重叠采样进行数据




图7 Sallen-Key 低通滤波器

增强,即获取训练故障特征时,每一段故障特征与其后一段特征之间有部分重叠,采样方式如图9所示.

具体做法是:在 HISPICE 环境搭建 Sallen-Key 低通滤波器电路,电路激励源为幅值 1 V、频率 1 000 Hz 的正弦波信号. 在仿真时间内,每类故障采样 158 000 个点,设每个故障样本长度为 51 529,偏移量为 1 064,那么重叠采样后最多可以制作 100 个样本,故障样本在归一化后转换成大小为 227×227 的灰度图像集.

每个实验对象选择 9 类故障,每类 100 张,共计 900 张图构成故障样本图像集,完成标注后按 6:2:2 的比例划分训练集、验证集、测试集. 表1为 Sallen-Key 滤波器电路故障模式,表2为二级四运放双二阶低通滤波器故障模式;图10为 Sallen-Key 滤波器电路各器件故障信号的时域图. 由图10可见,在 0 时刻附近,每类故障的特征区别并不明显.

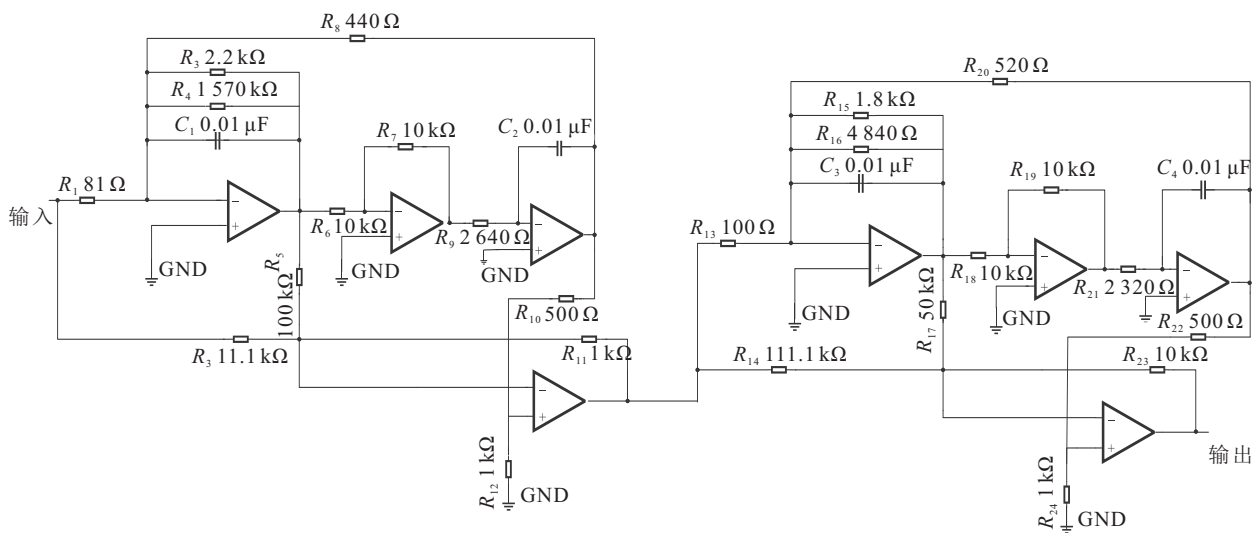


图8 二级四运放双二阶低通滤波器

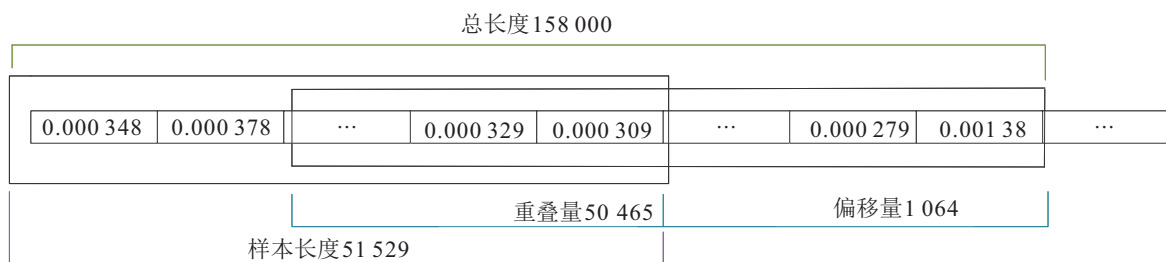


图9 重叠采样

表1 Sallen-Key滤波器电路故障模式

故障代码	故障类型	容差/%	标称值	故障值
$f_1$	无故障	—	—	—
$f_2$	$R_2$ 增大	5	3 k $\Omega$	4.5 k $\Omega$
$f_3$	$R_2$ 减小	5	3 k $\Omega$	1.5 k $\Omega$
$f_4$	$R_3$ 增大	5	2 k $\Omega$	3.0 k $\Omega$
$f_5$	$R_3$ 减小	5	2 k $\Omega$	1.0 k $\Omega$
$f_6$	$C_1$ 增大	10	5 $\mu$ F	7.5 $\mu$ F
$f_7$	$C_1$ 减小	10	5 $\mu$ F	2.5 $\mu$ F
$f_8$	$C_2$ 增大	10	5 $\mu$ F	7.5 $\mu$ F
$f_9$	$C_2$ 减小	10	5 $\mu$ F	2.5 $\mu$ F

表2 二级四运放双二阶低通滤波器电路故障模式

故障代码	故障类型	容差/%	标称值	故障值
$f_1$	无故障	—	—	—
$f_2$	$R_3$ 增大	5	2.2 k $\Omega$	3.4 k $\Omega$
$f_3$	$R_3$ 减小	5	2.2 k $\Omega$	1.1 k $\Omega$
$f_4$	$R_7$ 增大	5	10 k $\Omega$	15.0 k $\Omega$
$f_5$	$R_7$ 减小	5	10 k $\Omega$	10.0 k $\Omega$
$f_6$	$R_9$ 增大	5	2640 $\Omega$	3960 $\Omega$
$f_7$	$R_9$ 减小	5	2640 $\Omega$	1320 $\Omega$
$f_8$	$C_4$ 增大	5	0.01 $\mu$ F	0.015 $\mu$ F
$f_9$	$C_4$ 减小	5	0.01 $\mu$ F	0.005 $\mu$ F

2.3 实验流程


实验流程共计6步,分别是数据采集、故障编码、数据处理、数据划分、模型训练和模型测试.具体步骤如下:

- 1) 被测电路两端施加脉冲信号,采集故障数据.
- 2) 利用图像处理技术扩大数据集,将数据集转为图片集.
- 3) 故障编码.
- 4) 图片集按照6:2:2的比例划分为训练集、验证集和测试集.
- 5) 利用训练集训练网络模型,并用验证集调整网络模型使模型达到最优.
- 6) 模型测试时,将测试集的真实编码与模型的预测编码进行对比,若一致则分类正确,反之分类错误.

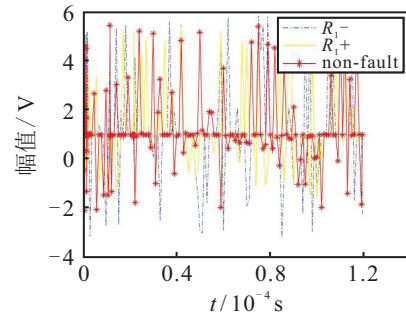
2.4 Sallen-Key滤波器电路诊断测试

以中心频率为25 kHz的Sallen-Key低通滤波器为例,采用Matlab对滤波器中单一的电阻或电容出现的“偏大”“偏小”“正常”这3种情况(如表1所示)共计9种故障进行仿真实验.


根据灵敏度测试结果可知,电阻 $R_2$ 、 $R_3$ 和电容 $C_1$ 、 $C_2$ 四种元器件对电路输出影响较为明显,故选择上述4个元器件作为研究对象进行实验分析.




(a)  $C_1$ 故障信号时域



(b)  $R_1$ 故障信号时域



(c)  $C_2$ 故障信号时域



(d)  $R_2$ 故障信号时域

图10 Sallen-Key滤波器故障信号时域图

其中,对电阻的容差设置为5%,电容的容差设置为10%. Sallen-Key滤波器中,当电阻或电容的大小超过所设容差时,表明电阻或电容偏大;当电阻或电容值低于所设容差时,表明电阻或电容偏小;当电阻或电容值在所设容差之内时,表明阻值或电容值正常.

为降低实验随机性对诊断性能评判的影响,对Sallen-Key低通滤波器电路进行10次独立诊断实验,其中最高诊断准确率如图11所示.由图11可见,9种故障能够被准确识别.

为验证CBAM-CNN网络对复杂模拟电路故障




图 11 Sallen-Key 滤波器诊断结果混淆矩阵

诊断与分类的有效性和优越性,将本文方法与一些常用模拟电路故障诊断与分类的方法进行对比实验.采用BP、SVM、ELM三种常用网络对数据进行故障分类,结果表明3种网络模型很难对本文实验数据进行有效分类.经分析后发现,在较短时间内提取的数据之间变化细微,对比不强,故特征提取不明显.因此,可以采用小波变换法(wavelet transform, WTF)与主成分分析法(principal component analysis, PCA)相结合的方式提取特征,达到降低数据维度、有效提取特征数据的效果,提高浅层网络分类准确率.图12列举了单独10次实验诊断结果较好的几种方法,所选方法的平均诊断结果如表3所示.图13(a)为小波变换的能量特征图,图13(b)为PCA特征能量图.

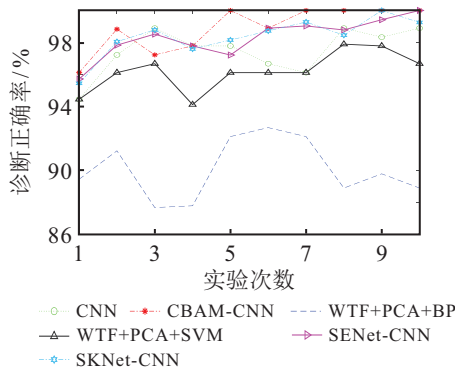




图 12 Sallen-Key 滤波器故障诊断正确率

表 3 Sallen-Key 滤波器故障诊断平均正确率

方法	平均正确率 / %
BP	16.67
ELM	36.11
SVM	41.67
WTF+PCA+ELM	54.65
WTF+PCA+BP	91.66
WTF+PCA+SVM	96.20
CNN 网络	97.50
SENet-CNN 网络	98.23
SKNet-CNN 网络	98.34
CBAM-CNN 网络	99.67



(a) Sallen-Key 低通滤波器小波变换能量图



(b) Sallen-Key 低通滤波器PCA特征能量图

图 13 Sallen-Key 滤波器故障特征能量

由图12和表3可知,在Sallen-Key滤波器10次实验测试中,CBAM-CNN网络的平均诊断正确率为99.67%,始终维持在较高水准,无误差分类的次数达5次;SENet-CNN网络与SKNet-CNN网络优于传统CNN网络,平均诊断正确率分别为98.23%、98.34%和97.50%.表明在CNN网络中添加注意力机制模块对特征的提取更加合理,而CBAM-CNN网络优于SENet-CNN网络与SKNet-CNN网络是因为CBAM将通道和空间两种特征进行融合,对特征的提取更加合理.SVM的正确率维持在90%~95%之间,最终平均诊断正确率为96.20%;BP和ELM的正确率分别为91.66%和54.65%,远远低于SVM;CBAM-CNN与SVM相比正确率略高,并且可达到100%.在简单电路、简单特征的情况下,深度学习的优势并不明显.

### 2.5 二级四运放双二阶低通滤波器电路诊断测试

为了验证本文网络在高阶模拟电路中的故障诊断能力,以二级四运放双二阶低通滤波器为对象进行实验.电路激励源为幅值10V、频率100Hz的脉冲信号,电阻和电容的容差均设置为5%,在HISPICE仿真中得到故障数据.根据灵敏度测试结果,选取对电路性能影响较大的电路元器件电阻 $R_3$ 、 $R_7$ 、 $R_9$ 和电容 $C_4$ 作为研究对象.同样以容差作为故障分类依据,故障模式为9类(如表2所示),在相同的实验条件下进行电路故障诊断分类实验.

在对二级四运放双二阶低通滤波器10次独立诊断实验中,最高诊断准确率如图14所示.图15所示为单独10次实验中诊断结果较好的几种方法.所选方

法的平均诊断结果如表4所示.图16为二级四运放双二阶低通滤波器故障特征能量分布.

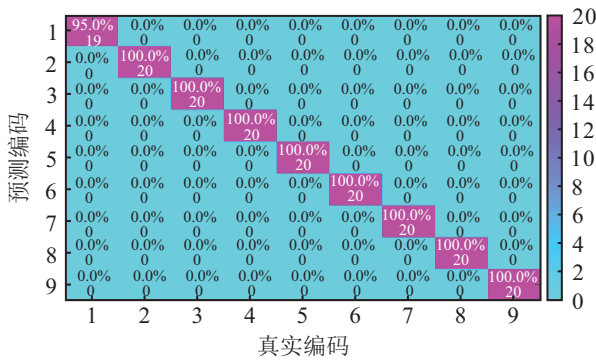


图14 二级四运放双二阶低通滤波器诊断结果混淆矩阵





图15 二级四运放双二阶低通滤波器故障诊断正确率


表4 二级四运放双二阶低通滤波器故障诊断平均正确率

方法	平均正确率/%
BP	15.74
ELM	35.20
SVM	40.97
WTF+PCA+ELM	49.82
WTF+PCA+BP	54.71
WTF+PCA+SVM	82.00
CNN网络	89.03
SENet-CNN网络	91.18
SKNet-CNN网络	92.43
CBAM-CNN网络	95.48

由图16和表4可知,在二级四运放双二阶低通滤波器10次实验测试中,CBAM-CNN的最终平均诊断正确率为95.48%;SENet-CNN网络与SKNet-CNN网络的平均诊断正确率依旧高于CNN网络,但低于CBAM-CNN,再一次验证了将通道与空间特征融合在一起的合理性与优越性;SVM正确率均在90%以下,最终平均诊断正确率为82.00%;BP和SVM的错分类率接近50%.根据上述可知,CBAM-CNN无需复杂的数据预处理即可提高诊断效率,且对于复杂的模拟电路故障诊断更具优势.



(a) 二级四运放双二阶低通滤波器小波变换能量



(b) 二级四运放双二阶低通滤波器PCAG特征能量

图16 二级四运放双二阶低通滤波器故障特征能量

### 3 结论

本文基于注意力机制,提出了一种CBAM-CNN模拟电路故障诊断模型,主要结论如下:利用重叠采样对样本数据增强处理,能够改善模型泛化性能;在CNN网络中添加BN层,能够加速网络收敛,提高学习速率和诊断效率,有效降低过拟合现象的产生风险;与自注意力机制相结合,能够充分发挥合理分配通道的重要性,合理选择提取重要特征.通道注意力与空间注意力相结合,相较于SENet和SKNet等注意力机制,能够更有效、更全面地提取故障特征信息,提高网络的诊断性能.

在Sallen-Key滤波器电路以及更复杂的二级四运放双二阶低通滤波器电路的诊断实验结果表明,相较于传统网络,所提出CBAM-CNN网络的特征提取能力和学习能力大幅度提高,诊断性能优越;相较于CNN网络以及结合注意力机制的SENet-CNN网络和SKNet-CNN网络,所提出CBAM-CNN网络同样具有明显优势,更适用于模拟电路故障诊断,可以为模拟电路故障诊断等领域提供新的解决方案.

### 参考文献(References)

[1] Sai S V A, Long B, Pecht M. Diagnostics and prognostics method for analog electronic circuits[J]. IEEE Transactions on Industrial Electronics, 2013, 60(11): 5277-5291.

[2] Jia R X, Wang J, Zhou J L. Fault diagnosis of industrial process based on the optimal parametric t-distributed stochastic neighbor embedding[J]. Science

- China Information Sciences, 2020, 64(5): 1-3.
- [3] 高明哲, 许爱强, 唐小峰, 等. 基于多核多分类相关向量机的模拟电路故障诊断方法[J]. 自动化学报, 2019, 45(2): 434-444.  
(Gao M Z, Xu A Q, Tang X F, et al. Analog circuit diagnostic method based on multi-kernel learning multiclass relevance vector machine[J]. Acta Automatica Sinica, 2019, 45(2): 434-444.)
- [4] 梅恒荣, 殷礼胜, 刘冬梅, 等. 改进粒子群算法优化的SVM模拟电路故障诊断[J]. 电子测量与仪器学报, 2017, 31(8): 1239-1246.  
(Mei H R, Yin L S, Liu D M, et al. Analogue circuit fault diagnosis based on SVM optimized by IPSO[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(8): 1239-1246.)
- [5] Tang X F, Xu A Q. Practical analog circuit diagnosis based on fault features with minimum ambiguities[J]. Journal of Electronic Testing, 2016, 32(1): 83-95.
- [6] Tadeusiewicz M, Hagas S. A method for local parametric fault diagnosis of a broad class of analog integrated circuits[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(2): 328-337.
- [7] Aminian M, Aminian F. A modular fault-diagnostic system for analog electronic circuits using neural networks with wavelet transform as a preprocessor[J]. IEEE Transactions on Instrumentation and Measurement, 2007, 56(5): 1546-1554.
- [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 C 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] Zhang C L, He Y G, Yuan L F, et al. A novel approach for diagnosis of analog circuit fault by using GMKL-SVM and PSO[J]. Journal of Electronic Testing, 2016, 32(5): 531-540.
- [10] Gan X S, Gao W M, Dai Z, et al. Research on WNN soft fault diagnosis for analog circuit based on adaptive UKF algorithm[J]. Applied Soft Computing, 2017, 50: 252-259.
- [11] Cui J, Wang Y R. A novel approach of analog circuit fault diagnosis using support vector machines classifier[J]. Measurement, 2011, 44(1): 281-289.
- [12] Wang P, Yang S Y. A new diagnosis approach for handling tolerance in analog and mixed-signal circuits by using fuzzy math[J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2005, 52(10): 2118-2127.
- [13] Li Q, Wu X, Liu T M. Differentiable neural architecture search for optimal spatial/temporal brain function network decomposition[J]. Medical Image Analysis, 2021, 69: 101974.
- [14] 段晨东, 何正嘉, 姜洪开. 非线性小波变换在故障特征提取中的应用[J]. 振动工程学报, 2005, 18(1): 129-132.  
(Duan C D, He Z J, Jiang H K. Fault feature extraction using nonlinear wavelet transform[J]. Journal of Vibration Engineering, 2005, 18(1): 129-132.)
- [15] Cohen A, Tiplica T, Kobi A. Design of experiments and statistical process control using wavelets analysis[J]. Control Engineering Practice, 2016, 49: 129-138.
- [16] Tadeusiewicz M, Hagas S. A new approach to multiple soft fault diagnosis of analog BJT and CMOS circuits[J]. IEEE Transactions on Instrumentation and Measurement, 2015, 64(10): 2688-2695.
- [17] Xiao Y Q, Feng L G. A novel linear ridgelet network approach for analog fault diagnosis using wavelet-based fractal analysis and kernel PCA as preprocessors[J]. Measurement, 2012, 45(3): 297-310.
- [18] 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.  
(Wang L, Liu Z Q. Fault diagnosis of analog circuit for WPA-IGA-BP neural network[J]. Systems Engineering and Electronics, 2021, 43(4): 1133-1143.)
- [19] Zhang L H, Qin Q, Shang Y, et al. Application of DE-ELM in analog circuit fault diagnosis[C]. Prognostics and System Health Management Conference. Chengdu, 2016: 1-6.
- [20] Gu Q H, Chang Y X, Li X H, et al. A novel  $F$ -SVM based on FOA for improving SVM performance[J]. Expert Systems with Applications, 2021, 165: 113713.
- [21] He W, He Y G, Li B. Generative adversarial networks with comprehensive wavelet feature for fault diagnosis of analog circuits[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(9): 6640-6650.
- [22] Fang F, Li L Y, Gu Y, et al. A novel hybrid approach for crack detection[J]. Pattern Recognition, 2020, 107: 107474.
- [23] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [24] Zhao G Q, Liu X Y, Zhang B, et al. A novel approach for analog circuit fault diagnosis based on deep belief network[J]. Measurement, 2018, 121: 170-178.
- [25] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [26] Mohamed A R, Dahl G E, Hinton G. Acoustic modeling using deep belief networks[J]. IEEE Transactions on Audio, Speech, and Language Processing, 2012, 20(1): 14-22.
- [27] Zhang C L, He Y G, Yuan L F, et al. Analog circuit incipient fault diagnosis method using DBN based features extraction[J]. IEEE Access, 2018, 6: 23053-23064.
- [28] Liu Z B, Jia Z, Vong C M, et al. Capturing high-discriminative fault features for electronics-rich

- analog system via deep learning[J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1213-1226.
- [29] Wang Z R, Wang J, Wang Y R. An intelligent diagnosis scheme based on generative adversarial learning deep neural networks and its application to planetary gearbox fault pattern recognition[J]. Neurocomputing, 2018, 310: 213-222.
- [30] He Z, Liu H, Wang Y W, et al. Generative adversarial networks-based semi-supervised learning for hyperspectral image classification[J]. Remote Sensing, 2017, 9(10): 1042.
- [31] Du T, Zhang H, Wang L. Analogue circuit fault diagnosis based on convolution neural network[J]. Electronics Letters, 2019, 55(24): 1277-1279.
- [32] Yang H 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.
- [33] 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.
- [34] 阳景, 潘强, 潘红兵. 基于时间卷积网络的模拟电路故障诊断方法[J]. 电子测量技术, 2019, 42(5): 128-132. (Yang J, Pan Q, Pan H B. Fault diagnosis method of analog circuits based on temporal CNN[J]. Electronic Measurement Technology, 2019, 42(5): 128-132.)
- [35] Zhang C G, Zha D R, Wang L, et al. A novel analog circuit soft fault diagnosis method based on convolutional neural network and backward difference[J]. Symmetry, 2021, 13(6): 1096.
- [36] Liu R N, Meng G T, Yang B Y, et al. Dislocated time series convolutional neural architecture: An intelligent fault diagnosis approach for electric machine[J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1310-1320.
- [37] Pan J, Zi Y Y, Chen J L, et al. LiftingNet: A novel deep learning network with layerwise feature learning from noisy mechanical data for fault classification[J]. IEEE Transactions on Industrial Electronics, 2018, 65(6): 4973-4982.
- [38] Wang J, Zhang W Q, Zhou J L. Fault detection with data imbalance conditions based on the improved bilayer convolutional neural network[J]. Industrial & Engineering Chemistry Research, 2020, 59(13): 5891-5904.
- [39] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 7132-7141.
- [40] Li X, Wang W H, Hu X L, et al. Selective kernel networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, 2019: 510-519.
- [41] Woo S, Park J, Lee J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the 15th European Conference on Computer Vision. Munich, 2018: 3-19.
- [42] 张红斌, 熊其鹏, 蒋子良, 等. 联合SENet异构层特征融合与集成学习的材质图像识别[J]. 控制与决策, 2022, 37(6): 1631-1642. (Zhang H B, Xiong Q P, Jiang Z L, et al. Material image recognition combining heterogeneous-layer feature fusion of SENet and ensemble learning[J]. Control and Decision, 2022, 37(6): 1631-1642.)
- [43] Fu H X, Song G Q, Wang Y C. Improved YOLOv4 marine target detection combined with CBAM[J]. Symmetry, 2021, 13(4): 623.
- [44] 司念文, 张文林, 屈丹, 等. 卷积神经网络表征可视化研究综述[J]. 自动化学报, DOI: 10.16383/j.aas.c200554. (Si N W, Zhang W L, Qu D, et al. Representation visualization of convolutional neural networks: A research survey[J]. Acta Automatic Sinica, DOI: 10.16383/j.aas.c200554.)
- [45] Gan M, Wang C, Zhu C A. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings[J]. Mechanical Systems and Signal Processing, 2016, 72/73: 92-104.

## 作者简介

杜先君 (1979—), 男, 副教授, 博士, 从事复杂系统建模、控制与诊断等研究, E-mail: xdu@lut.edu.cn;

巩彬 (1997—), 女, 硕士生, 从事模拟电路故障诊断的研究, E-mail: gong\_bin01@163.com;

余萍 (1979—), 女, 副教授, 博士, 从事故障诊断与预测等研究, E-mail: yup@lut.edu.cn;

石耀科 (1990—), 男, 博士生, 从事健康管理与寿命预测的研究, E-mail: yaoke\_shi@163.com;

Kuzina V. Angelina (1998—), 女, 硕士生, 从事集成电路故障诊断的研究, E-mail: angelok3103@yandex.ru;

程生毅 (1987—), 男, 副教授, 博士, 从事模型优化与应用等研究, E-mail: 415438596@qq.com.

(责任编辑: 郑晓蕾)