

DOI: 10.13382/j.jemi.B2407659

# 基于 Koopman 算子与一维自编码卷积神经网络的 模拟电路软故障诊断\*

段涛<sup>1,2</sup> 刘美容<sup>1</sup> 高雄<sup>1</sup> 何怡刚<sup>2</sup>

(1. 湖南师范大学物理与电子科学学院 长沙 410081; 2. 武汉大学电气与自动化学院 武汉 430072)

**摘要:** 模拟电路是现代电子系统中的核心组成部分,随着电子设备日益复杂,传统的故障诊断方法已无法应对现代模拟电路中的故障检测需求,尤其是在软故障诊断中,因信号响应相似而导致故障定位困难。为解决这一问题,提出了一种基于 Koopman 算子的纯数据驱动故障检测方法。首先,通过延迟嵌入法构建 Hankel 矩阵,将电路输出信号映射至高维空间,从而实现系统全局线性化;然后,利用动态模式分解求解 Koopman 算子,在 Koopman 算子的特征空间内分析模态分布及信号的模态能量占比,通过提取储存特征值变化的范德蒙矩阵得到关键模态,来构建具有良好可区分度的特征向量;最后,将其输入到卷积神经网络中来完成故障识别。为验证该方法的有效性,搭建了基于 Pspice 与 Simulink 的四运放双二阶高通滤波器电路的联合仿真模型,利用 SLPS 模块结合电路网表实现模拟电路状态参数自动采集。实验结果表明,所提出的方法具有较高的准确精度,平均准确率 99.86%,高于其他方法。

**关键词:** Koopman 算子; Hankel 矩阵; 动态模式分解; 故障诊断; 模拟电路

**中图分类号:** TP206; TN710 **文献标识码:** A **国家标准学科分类代码:** 510

## Soft fault diagnosis of analog circuits using 1 D self coding convolution neural network and Koopman operator

Duan Tao<sup>1,2</sup> Liu Meirong<sup>1</sup> Gao Xiong<sup>1</sup> He Yigang<sup>2</sup>

(1. School of Physics and Electronic Science, Hunan Normal University, Changsha 410081, China;

2. School of Electrical and Automation, Wuhan University, Wuhan 430072, China)

**Abstract:** Analog circuits are the core components of modern electronic systems, and as electronic devices become increasingly complex, traditional fault diagnosis methods are no longer able to meet the demand for fault detection in modern analog circuits, especially in soft fault diagnosis, where similar signal responses make fault localization difficult. To solve this problem, a pure data-driven fault detection method based on the Koopman operator is proposed. First, the Hankel matrix is constructed through the delay embedding method, which maps the circuit output signal to a high-dimensional space and achieves system global linearization. Then, the Koopman operator is solved using dynamic mode decomposition, and the modal distribution and signal modal energy ratio are analyzed in the Koopman operator's eigenfunction space. By extracting the Van der Monde matrix that stores the changes in the eigenvalue, the critical modes are obtained to construct a feature vector with good discriminability. Finally, it is input into a convolutional neural network to complete the fault identification. To verify the effectiveness of the method, a joint simulation model of a four-op-amp dual second-order high-pass filter circuit based on Pspice and Simulink was established, and the circuit state parameters were automatically collected using the SLPS module combined with the circuit netlist. The experimental results show that the proposed method has a high accuracy, with an average accuracy of 99.86%, which is higher than other methods.

**Keywords:** Koopman operator; Hankel Matrix; dynamic mode decomposition; fault diagnosis; analog circuits

## 0 引言

随着电路电子技术的迅速发展,电路系统朝着“大数字,小模拟”的电路结构演变。据相关研究表明,模拟和数字电路在混合电路中的比例约为 60%,并将继续增长,尽管模拟元件仅占混合电路的 20%,但测试和诊断模拟元件的成本已达到总成本的 80%<sup>[1-2]</sup>。因此,模拟电路的性能对整个电路系统的稳定性与可靠性具有决定性影响<sup>[3]</sup>。

模拟电路故障分为硬故障和软故障,硬故障指的是电路元件或连接器的物理损坏或失效,例如电阻值超出规定范围、电容短路、晶体管断路等。这些故障通常是由于材料老化、机械应力、温度变化或生产过程中的缺陷等原因导致的,是比较明显的故障<sup>[4]</sup>。软故障的情况下拓扑结构不会改变,但电路元件的参数会偏离其标称值会影响电路的性能,如果软故障没有及时修复,它就会变成硬故障,其往往更难以检测和诊断,因为它们可能是瞬时的,随着环境条件的变化而改变<sup>[5-6]</sup>。因此,软故障理论与技术一直是故障诊断领域研究的热点。

模拟电路软故障是复杂多样的,且元件参数具有容差性等特点,使用传统方法很难有效提取故障的特征状态,诊断效率不高<sup>[7]</sup>。随着人工智能技术的发展,神经网络<sup>[8]</sup>、支持向量机<sup>[9]</sup>和群智能优化算法<sup>[10-11]</sup>逐渐被引入到故障诊断领域中,它们几乎不依赖于先验知识,而是通过机器学习算法挖掘各故障类型与数据样本间的关系<sup>[12-13]</sup>。文献[14]提出了一种在线故障诊断方法,基于深度迁移卷积神经网络从转换后的图像数据中提取代表性特征对故障进行分类。文献[15]选用一种复杂卷积自注意自动编码器来执行模拟电路的早期故障诊断,通过捕捉内部相关性来增强特征表示的有用结构信息,从而解决早期故障的微弱性质和部件的容差。为了精确定位电路中的软故障,文献[16]通过格拉姆角和场和递归图方法将模拟电路的时间响应序列信号转换成灰度图像,来获得更多时间响应序列信号的特征信息。文献[17]在软故障区间随机生成训练样本,以适应部件参数的不断变化,但需要在软故障区间内获取大量训练样本,诊断率略低于固定参数偏移的软故障。然而,大多数方法侧重于将系统视为黑盒模型,需要大量低噪声、高采样的时间序列数据来获得系统输入输出之间的正确关系。

Koopman 算子能够得到系统动态的可解释性表示,可以仅依靠系统运行数据建立非线性系统的线性模型,以此利用线性系统分析工具实现对非线性系统的分析<sup>[18-20]</sup>。Koopman 算子是一种表示非线性动力系统的线性演化算子,它的新颖用途在于提取非线性系统的重要

特征参数。文献[21]提出了一种非线性无模型故障检测与隔离方法,其关键思想是建立基于 Koopman 的非线性动力系统降阶模型,实现全局范围内非线性系统故障诊断。文献[22]为了捕捉时间序列数据的底层非线性动态生成过程,在 Koopman 模型形式的空间上引入了不同的距离概念,利用线性观测器实现非线性系统的预测。文献[23]利用深度神经网络获得 Koopman 状态提升函数集,增强 Koopman 框架对实际问题的适用性。

当前许多软故障诊断方法通常需要精确的电路模型或对信号特征分布的深刻了解,难以应对复杂非线性电路和未知故障模式,当软故障信号受噪声或环境条件影响较大时,诊断精度往往显著下降。而本文采用了 Koopman 算子结合动态模式分解(dynamic mode decomposition, DMD)的方法, Koopman 算子可以通过非线性系统的线性化处理揭示复杂系统的全局特性,而动态模式分解为求解 Koopman 算子提供了数据驱动的高效方式。在高维空间中,信号与噪声的分布可能呈现不同的模式,通过延迟嵌入法结合 Koopman 算子,将信号映射至高维空间后,通过分析模态特征可有效分离信号特征与干扰成分,增强软故障信号的区分能力。该方法结合了 Koopman 理论、机器学习和线性系统的一般框架,结果表明,与现有的数据驱动方法相比,所提方法具有更高的诊断精度、更低的数据要求和更稳定的故障诊断性能。

## 1 Koopman 模态分解

### 1.1 Koopman 算子

Koopman 算子可描述非线性系统的可观测状态在高维空间中的线性演化过程<sup>[23]</sup>,但该算子是一个无穷维的线性变换,一般用有限维的线性变换来近似。对于一个非线性动态系统:

$$x_{t+1} = f(x_t) \quad (1)$$

式中:  $x_t$  表示  $t$  时刻系统状态;  $f$  为相邻时刻系统状态的非线性映射。定义 Koopman 算子  $K$  是一个作用在观测函数  $\psi(x_t)$  上的线性运算符,通过观测函数  $\psi(x)$  将原系统转换至无穷维空间,在无穷维空间中系统通过  $K$  线性演进。基于 Koopman 算子的系统演进示意图如图 1 所示,其实质是通过在原系统进行坐标变换实现非线性系统的全局线性化,满足:

$$K\psi(x_t) = \psi(f(x_t)) \quad (2)$$

### 1.2 动态模式分解

动态模式分解是一种从高维数据中发现动力系统的技术。Rowley 等<sup>[24]</sup>证明了在一定条件下, DMD 提供无限维 Koopman 算子特征值和特征向量的有限维近似,通过奇异值分解算法寻求 Koopman 算子  $K$  的相似矩阵  $\bar{K}$  进

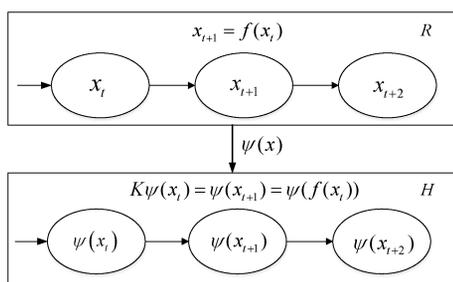


图 1 基于 Koopman 算子的系统演进示意图

Fig. 1 Schematic diagram of system evolution based on Koopman operator

而得出原始序列的动力学特征模式。DMD 方法从实验数据计算有限维线性模型的特征值和特征向量,该计算方法可近似于无限维的 Koopman 算子,同时给出与每个模态相关的增长率和频率。

对于一维  $N$  个采样点的时间序列  $S$ , 构建 Hankel 矩阵  $S_{Hankel}$ 。为了实现信号与噪声的充分分离,重构矩阵时应保证行数与列数的乘积尽可能大<sup>[25]</sup>, 根据不等式定理,当  $m$  和  $n$  相等或者接近时两者的乘积能够取得最大值。因此可以用  $x_N$  的时移副本来丰富测量数据,这些副本被称为延迟坐标,延迟嵌入被广泛应用于分析和表征混沌系统中的吸引子,如 Kantz 等<sup>[25]</sup> 利用 Koopman 算子获得混沌动力学的间歇性强制线性逼近。在 Takens 嵌入定理规定的条件下可以进行相空间重构,其广义延迟坐标也被用于特征系统实现算法的线性系统识别<sup>[26]</sup>。

$$S_{Hankel} = \begin{bmatrix} x_1 & x_2 & \cdots & x_n \\ x_2 & x_3 & \cdots & x_{n+1} \\ \cdots & \cdots & \cdots & \cdots \\ x_i & x_{i+1} & \cdots & x_{n+i-1} \\ \cdots & \cdots & \cdots & \cdots \\ x_m & x_{m+1} & \cdots & x_N \end{bmatrix} = \begin{bmatrix} X_1 & X_2 & \cdots & X_N \end{bmatrix} \quad (3)$$

$$S_{Hankel} \in R^{m \times n} \quad (4)$$

其中,  $m$  为时滞参数,可由自相关或互信息等方法获得,  $n$  满足  $m + n - 1 = N$ <sup>[25]</sup>。

通过模拟实验采集系统数据如式(5)和(6)所示,将其在时间维度上分成两个连续的矩阵。

$$X = [X_1 \ X_2 \ \cdots \ X_{n-1}] \quad (5)$$

$$Y = [X_2 \ X_3 \ \cdots \ X_n] \quad (6)$$

其中,  $X, Y \in R^{m \times (n-1)}$ ,  $X_i \in R^{m \times 1}$  是时间步  $i$  处定义系统的  $m$  维状态的列向量,采用 DMD 计算最佳拟合线性算子  $A$  与数据  $Y$  的联系:

$$A = YX^\dagger \quad (7)$$

DMD 模态也称为动态模式,每个 DMD 模态对应于

$A$  的特定特征值。当状态维度  $n$  较大时,矩阵  $A$  可能难以直接分析,DMD 通过减少 POD 投影矩阵  $\bar{A}$  的秩来规避  $A$  的完全特征分解。

1) 对矩阵  $X$  进行奇异值分解:

$$X \approx U \Sigma V^* \quad (8)$$

其中,  $*$  表示共轭转置,  $U$  和  $V$  分别为左特征向量和右特征向量,  $U$  和  $V$  的列向量是正交的,因此  $U^* U = I$ ,  $V^* V = I$  ( $U \in C^{n \times r}$ ,  $\Sigma \in C^{r \times r}$ ,  $V \in C^{m \times r}$ )  $\Sigma$  为包含  $r$  个非 0 的特征值的对角矩阵。

2) 进行低秩截断,如果数据中存在低维结构,  $\Sigma$  的奇异值将急剧下降到零,只有有限数量的主导模式。选取一个给定的秩  $r$ , 其奇异值的和占了全部奇异值之和的 99% 以上的比例,基于上式可得:

$$A = YV_r \Sigma_r^{-1} U_r^* \quad (9)$$

将其投影到  $r$  阶特征向量中,得到相似矩阵:

$$\bar{A} = U_r^* A U_r = U_r^* YV_r \Sigma_r^{-1} \quad (10)$$

经相似变换后的矩阵  $\bar{A}$  与原矩阵  $A$  具有相同的特征值,且  $A$  的特征向量可以通过  $\bar{A}$  的特征向量表示。

3) 对相似矩阵  $\bar{A}$  进行特征值分解:

$$\bar{A} = W \Lambda W^{-1} \quad (11)$$

式中:  $W$  的每一列是特征向量,  $\Lambda \in R^{r \times r}$  对角矩阵  $\Lambda = \text{diag}([\lambda_1 \ \lambda_2 \ \cdots \ \lambda_r])$ , 包含矩阵  $\bar{A}$  的复特征值。

4) 从  $W$  和  $\Lambda$  重构  $A$  的特征分解。其中,  $A$  的特征值由  $\Lambda$  给出,  $A$  的特征向量(DMD 模式)由  $\Phi$  的列给出:

$$\Phi = YV \Sigma^{-1} W \quad (12)$$

式(12)由特征值和特征向量的低阶矩阵逼近得到。动力学模式分解重构矩阵通过  $r$  阶特征向量求和得到:

$$X_{DMD} = \sum_{i=1}^r \phi_i \exp(\lambda_i \Delta t) b_i = \Phi \exp(\Omega t) b \quad (13)$$

式中:  $\Phi$  为由动力学模式分解特征向量  $\phi_i$  组成的矩阵,  $\Omega = \text{diag}(\lambda_j)$  为相似矩阵  $\bar{A}$  的特征值  $\lambda_j$  组成的对角阵,  $b$  为所有模式的幅值,  $b = \Phi^\dagger x_1$  其中  $x_1$  为初始快照  $t_1 = 0$  的值,  $\dagger$  表示广义逆。DMD 与 Koopman 框架示意图如图 2 所示。

## 2 基于一维卷积神经网络(1D-CNN)的故障分类器

### 2.1 卷积神经网络

卷积神经网络是一类特殊的深度神经网络,特别适合处理图像和其他具有网格结构的数据。其通过一系列层次结构来提取数据的特征和模式<sup>[27]</sup>。它可以使用反

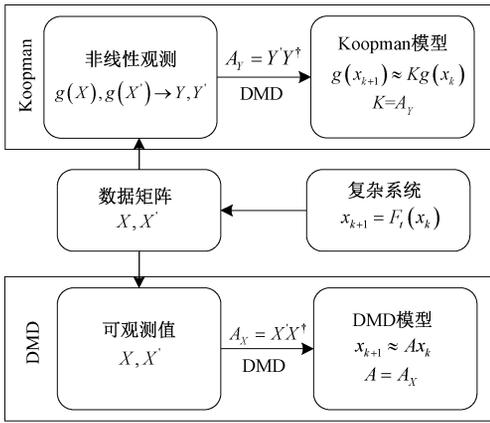


图2 DMD与Koopman框架示意图

Fig. 2 Schematic diagram of DMD and Koopman framework

向传播算法进行端到端的训练,通过优化损失函数来更新模型参数,使得模型能够逐步学习到输入数据的特征表示,因此成为了深度学习领域中一种颇具吸引力的结构<sup>[28]</sup>。

感受野的大小取决于网络结构中的各个层的参数,包括卷积核的大小、池化层的窗口大小和步幅,图3所示为感受视野为3×3的卷积。

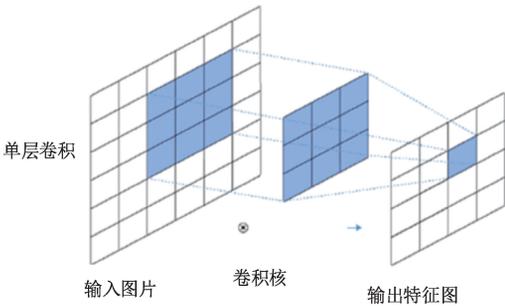


图3 感受视野为3×3的卷积

Fig. 3 Convolution of 3×3 visual field

假设第  $l$  层的感受视野为  $R_l$ , 卷积核大小为  $K_l$ , 步幅为  $S_l$ , 填充为  $P_l$ , 那么第  $l$  层的感受视野可以递归地表示为:

$$R_l = R_{l-1} + (K_l - 1) \times \prod_{i=1}^{l-1} S_i \quad (14)$$

式中:  $R_{l-1}$  是前一层的感受野大小;  $K_l$  是第  $l$  层的卷积核大小;  $S_l$  是第  $l$  层的步幅。

卷积运算的本质就是将一个滤波器(卷积核)在输入数据上滑动并进行逐元素乘积和求和的过程,实现对输入数据的特征提取和信息融合。卷积具有“权值共享”的特性<sup>[29]</sup>,即每个过滤器采用相同的卷积核来提取输入局部区域的特征,使得每个卷积核只需要学习一组参数,而不是针对每个可能的输入位置都学习一个单独的参数集。这种参数共享的方式大大减少了网络的参数

数量,降低了模型的复杂度。卷积操作可以定义为:

$$x_j^l = f\left(\sum_{i=1}^n x_i^{l-1} * \mathbf{k}_{ij}^l + \mathbf{b}_j^l\right) \quad (15)$$

式中:  $*$  表示局部区域的卷积,  $x_j^l$  表示第  $l$  层的第  $j$  个特征映射,  $\mathbf{k}$  和  $\mathbf{b}$  分别表示对应卷积层的权重矩阵和偏置,  $f$  表示非线性激活函数。

最大池化层定义为:

$$P_i^{l+1} = \max_{(n-1)d+d \leq k \leq nw} (q_i^l) \quad (16)$$

其中,  $P_i^{l+1}$  表示池化层的输出值,  $d$  表示卷积核的大小,  $q_i^l$  表示第  $l$  层中第  $i$  通道的神经元所对应的值。

将最后一层卷积池化层输出的  $n$  个通道进行全连接层操作,得到长度为  $n$  的向量,输入到 Softmax 分类器进行分类,其表达式为:

$$S(y_i) = e^{y_i} / \sum_{j=1}^m e^{y_j} \quad (17)$$

式中:  $y_i$  表示第  $i$  个输出神经元,  $m$  表示全连接层神经元的总数。

### 2.2 利用 Koopman 特征的 1D-CNN 故障诊断方法

Koopman 算子和 1D-CNN 故障检测框架如图4所示,首先,利用时间延迟嵌入构建 Hankel 矩阵,从原始信号中提取时间序列特征,并通过动态模态分解求解 Koopman 算子模型参数,提取系统的高维状态特征。然后,基于提取的状态特征构建 1D-CNN 模型,通过多层卷积、激活与池化操作捕获数据的深层特征,并利用全连接层与 Softmax 层完成故障类型的识别,该框架为模拟电路的软故障检测提供了一种新颖且高效的解决方案。此外,时间序列反映了系统的动态特征, Koopman 算子能直接从可观测量中考察状态空间中相关函数的演化,并保持相关的低频时空特征不变,对故障分析起到了一定的简化作用。

## 3 实验验证与结果分析

### 3.1 实验设置

Pspice 是以图形或文件的方式输入,进行数字、模拟电路混合仿真和计算的 EDA 软件,适用于分析各种电路拓扑结构和复杂的电路行为,其仿真精度高但速度较慢。而 Matlab/Simulink 是系统级建模和仿真工具,提供了丰富的建模工具和库可以建立系统级模型,并模拟系统的动态行为。在电路仿真中将两者相结合,集优势于一体来提高电路的仿真效率。例如,在 LNK364 开关电源系统中内部存在大量的 A/D 与 D/A 转换和小型数模混合电路系统,导致仿真时间比较长。在这种情况下,联合仿真用时约为 Pspice A/D 仿真的十分之一,由此可见联合仿真的优越性。首先在 Pspice 中进行仿真分析,在 MATLAB 中搭建其控制电路的 Simulink 模型,通过 SLPS

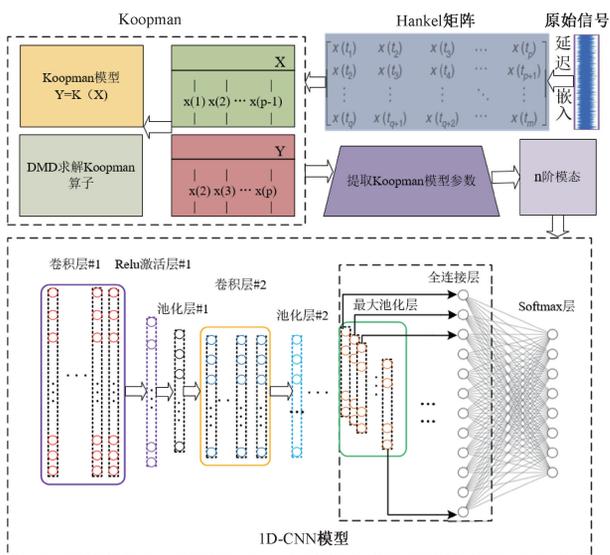


图 4 Koopman 算子和 1D-CNN 故障检测框架

Fig. 4 Koopman operator and 1D-CNN fault detection framework

模型接口工具相连接,实现 Pspice 软件与 MATLAB/Simulink 软件之间的数据通信,其交互与分析如图 5 所示,故障样本获取技术流程如图 6 所示,进行联合仿真来自动获取故障模式数据。

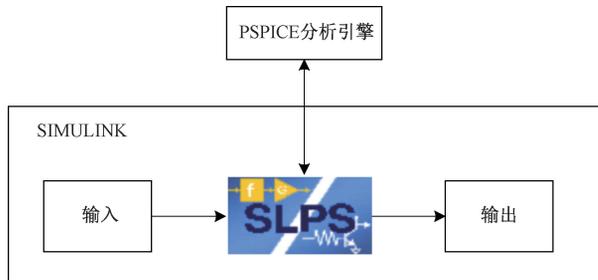


图 5 Pspice 与 Matlab 交互与分析

Fig. 5 Interaction and analysis between Pspice and Matlab

滤波器因有综合滤波功能,对信号频率具有选择性,在通信工程、自动控制、遥感测试等技术领域应用广泛。本实验基于四运放双二阶高通滤波器联合仿真如图 7 所示,电阻和电容的容差设置为 5% 和 10%。多个故障与单个故障的处理方法相同,也可当作单故障来处理,并且在实际应用中,多个故障同时发生的概率较低。采用灵敏度分析获取对电路性能影响最大的元件,并利用测量函数对输出结果进行测量。灵敏度分析结果如图 8 所示,详细列出了与标称测量值相比具有最大影响或偏差的元件,选取 C1、R1、R4、R5、R6、R9 作为被测元件。由于电路响应与参数间存在复杂的非线性关系,因此本研究故障诊断研究考虑元件发生软故障的情况,故障码及故障值如表 1 所示,其中 ↑ 和 ↓ 分别表示故障值高于和低于标称值。

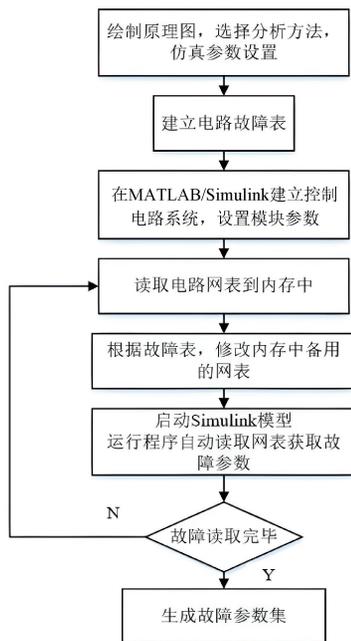


图 6 故障样本获取技术流程

Fig. 6 Technical flowchart for obtaining fault samples

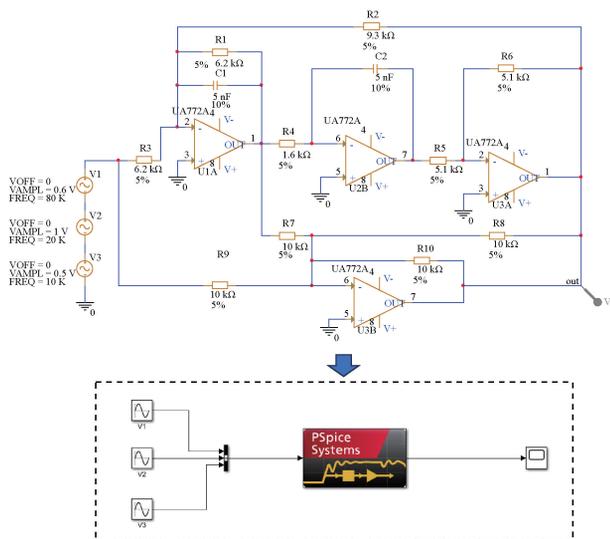


图 7 四运放双二阶高通滤波器电路联合仿真测试

Fig. 7 Joint simulation test of dual second-order high pass filter circuit with four operational amplifiers

Component	Parameter	Original	@Min	@Max	Rel Sensitivity	Linear
C1	VALUE	5n	5.000n	4.900n	-128.083m	23
R4	VALUE	1.600k	1.440k	1.760k	39.031m	31
R9	VALUE	10k	9k	11k	33.025m	26
R5	VALUE	5.100k	4.590k	5.610k	29.857m	23
R6	VALUE	5.100k	4.590k	5.610k	29.879m	23
R1	VALUE	6.200k	5.580k	6.820k	21.955m	18
R3	VALUE	6.200k	5.620k	6.580k	-19.010m	18
R2	VALUE	9.300k	10.230k	8.370k	-4.7149m	1
R10	VALUE	10k	9k	11k	1.1775m	1
C2	VALUE	5n	5.000n	4.900n	-150.053u	<100%
R7	VALUE	10k	9k	11k	1.1609m	<100%
R8	VALUE	10k	9k	11k	1.1775m	<100%

图 8 灵敏度分析结果

Fig. 8 Sensitivity analysis results

表 1 电路故障标签及模式

Table 1 Circuit fault label and mode

故障代码	故障类型	标称值	故障值
F0	——	——	——
F1	C1 ↑	5 nF	7.5 nF
F2	C1 ↓	5 nF	2.5 nF
F3	R1 ↑	6.2 kΩ	9.3 kΩ
F4	R1 ↓	6.2 kΩ	3.1 kΩ
F5	R4 ↑	1.6 kΩ	3.2 kΩ
F6	R4 ↓	1.6 kΩ	0.8 kΩ
F7	R5 ↑	5.1 kΩ	10.2 kΩ
F8	R6 ↑	5.1 kΩ	10.2 kΩ
F9	R6 ↓	5.1 kΩ	2.5 kΩ
F10	R9 ↑	10 kΩ	20 kΩ
F11	R9 ↓	10 kΩ	5 kΩ

3.2 实验分析与模型参数设置

通过模块调用接口工具,设置模块的输入输出端参数变量,图 9 所示为不同故障模式的输出信号。F0 状态信号 Pspice 输出的仿真波形与 Simulink 联合仿真输出波形分别如图 10 和 11 所示,可以看出两者波形基本一致,且联合仿真能在保证电路仿真精确度的情况下大大缩短仿真时间。

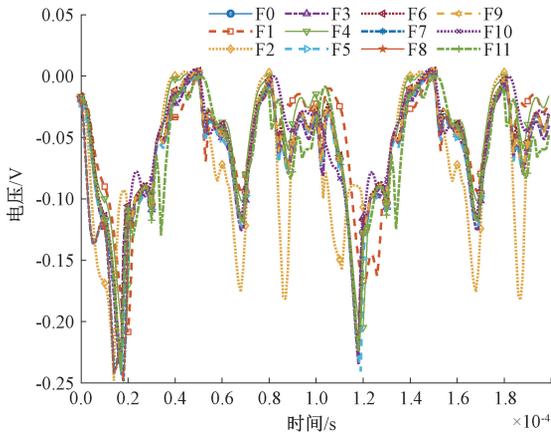


图 9 电路中不同故障模式的输出信号

Fig. 9 Output signals of different fault modes in the circuit

实验选取 1 ms 内被测电路输出电压,采样间隔为 1 μs,通过延迟嵌入式定理,构造每个样本故障状态下大小为 500 × 501 的 Hankel 矩阵,通过 DMD 分解求解 Koopman 算子。

用信号的能量对模态进行排序,每一时刻的信号等于初始信号乘以特征值。对于不同的模态,可以用范德蒙矩阵来存储其特征值的变化,利用式  $\phi_r \times b_r \times [1 \ \lambda_r^1 \ \dots \ \lambda_r^{N-1}]$  来得到特征值所对应的模态。正常

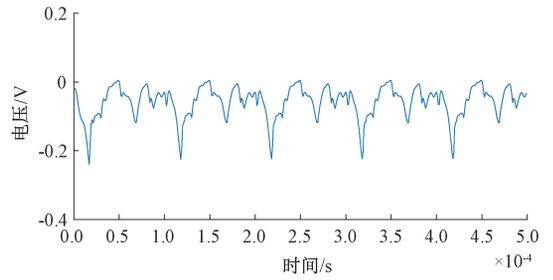


图 10 F0 状态信号 Pspice 输出的仿真波形

Fig. 10 Simulation waveform of F0 status signal Pspice output

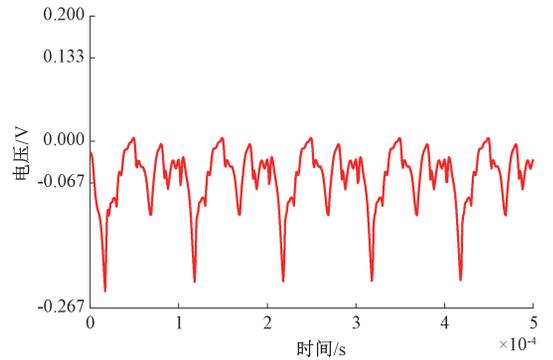


图 11 F0 状态 Simulink 联合仿真输出波形

Fig. 11 Output waveform of Simulink joint simulation in F0 state

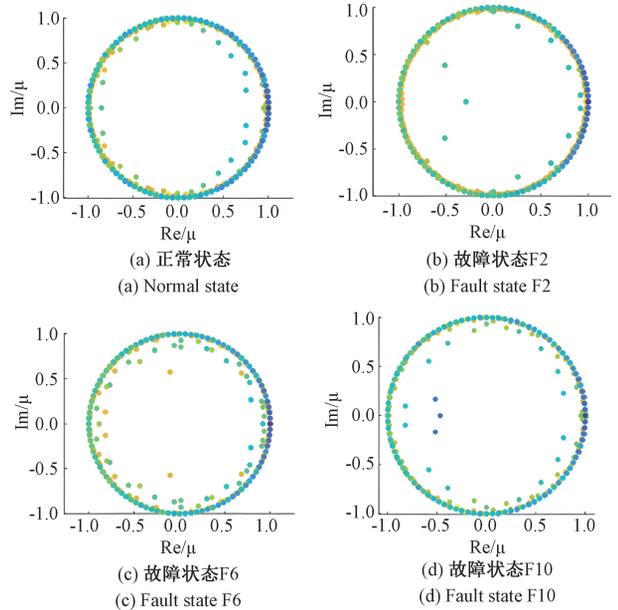
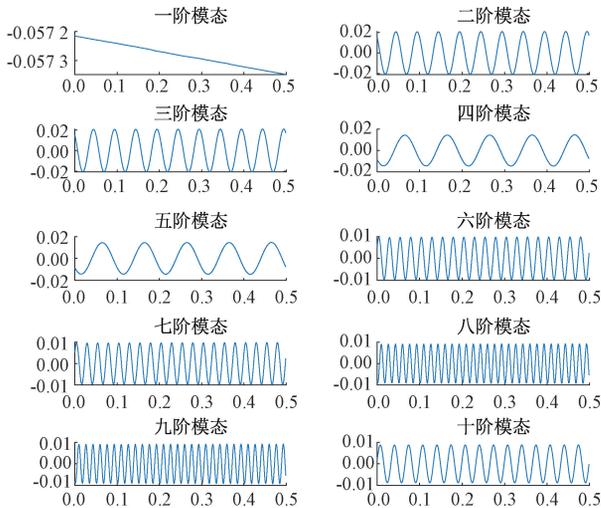


图 12 部分故障状态的 Koopman 算子特征根分布

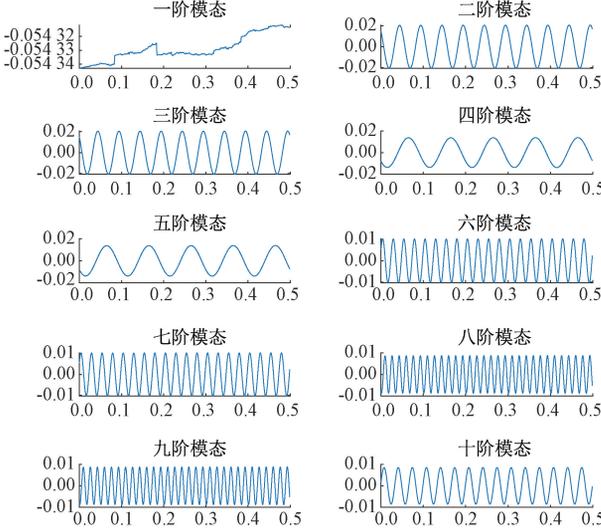
Fig. 12 Eigenroot distribution of Koopman operator for partial fault states

状态与各故障状态的 Koopman 算子的特征根分布如图 12 所示,其基本分布在单位圆上,能量越大其所对应的

特征值颜色越深。DMD 能很好地实现动态数据分析,在给定的时间序列数据中,计算中得到的每个模式都与固定的振荡频率和衰减/增长率相关联,且分解出的“模式”具有一定的物理意义,相较于主成分分析等静态技术给出的“特征向量”有更强的解释性。本文选取的秩  $r=400$ ,图 13 所示为正常状态与故障状态 F6 下的 Koopman 算子特征根对应的模式分布。各阶模式的能量占比如图 14 所示,可以看出前 10 阶信号能量几乎占到了 100%。因此提取其前 10 阶模式作为故障特征输入,训练样本与测试样本比例为 3 : 2。



(a) 正常状态下的Koopman算子特征根对应的模式分布  
(a) The modal distribution corresponding to the eigenvalues of Koopman operator in normal state



(b) 故障状态F6下的Koopman算子特征根对应的模式分布  
(b) Modal distribution corresponding to the eigenvalues of Koopman operator in fault state F6

图 13 故障状态的 Koopman 算子特征根对应的模式分布  
Fig. 13 Modal distribution corresponding to the eigenvalues of Koopman operator in fault states

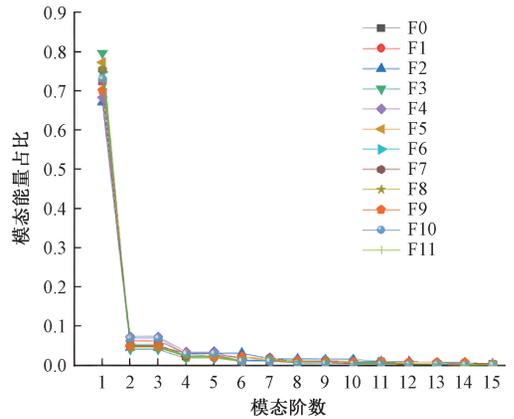


图 14 各阶模式占比

Fig. 14 Proportion of each mode

基于 1D-CNN 的分类器构造遵循端到端框架,图 15 为 1D-CNN 模型架构,为了获得更好的训练模型,采用 Adam 梯度算法,通过计算梯度的一阶矩估计和二阶矩估计为不同的参数设计独立的自适应性学习率,该电路的 1D-CNN 模型由两个块、fc 层和 softmax 分类器组成,卷积核分别为 32 和 64 个通道,大小为  $2 \times 1$ ,最大池化层的滑动窗长度分别为 1 和 2,第 1 层和第 2 层大小都为  $2 \times 1$ ,初始学习率为 0.001, L2 的正则化参数为 0.001,通过减少权重的固定比例来降低模型的复杂度避免过拟合。将样本输入到 1D-CNN 模型中进行训练测试,共迭代了 500 轮,每轮迭代的次数为 28,迭代过程中训练准确度与损失变化曲线如图 16 所示,均有很高的准确度,训练集与预测集的结果如图 17 和 18 所示,其中测试集准确度达到了 100%,说明了基于 Koopman 的数据驱动方法能够从原始时间序列中提取深度故障特征,1D-CNN 模型参数设置如表 2 所示。

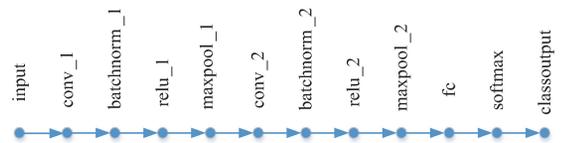


图 15 1D-CNN 模型架构

Fig. 15 1D-CNN model architecture

### 3.3 模型诊断结果及对比分析

为了进一步验证所提模型的性能,采用 10 倍交叉验证对比本文所提出 Koopman-CNN 方法与其他 3 种方法的故障诊断精度,分别为深度置信神经网络 (DBN),其中每个 RBM 的预训练迭代次数为 500 次,学习率动量分别为 0.11 和 0.9,自适应神经模糊推理系统 (ANIFS) 和主成分分析-支持向量机 (PCA-SVM),其中 SVM 采用 RBF 核函数和贝叶斯优化超参数。测试结果显示所提出

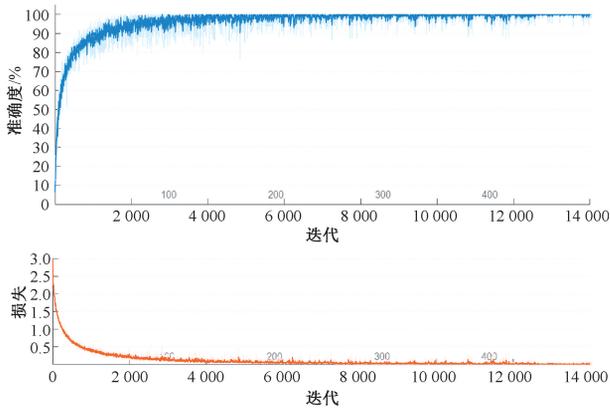


图 16 模型训练准确度与损失变化曲线

Fig. 16 Change curve of model training accuracy and loss

模型的平均诊断精度达到了 99.86%,要优于 DBN、ANIFS 与 PCA-SVM,同时该方法具有实时测试的优势,其训练时间为 362 s,测试时间只需 0.015 s。由于该方法结合了 Koopman 算子与 DMD 模态分解各自的优势,提取的故障特征向量具有良好的可区分度,明显提高了故障诊断稳定性,对比算法的平均诊断精度如表 3 所示。

表 2 1D-CNN 模型参数设置

Table 2 Parameter Settings of 1D-CNN model

序号	名称	激活	可学习参数
1	input	10×1×1	—
2	10×1×1 ‘zerocenter’ 归一化	—	—
2	conv_1	9×1×32	weights 2×1×1×32
3	32 2×1×1 卷积 步幅[1 1]	—	bias 1×1×32
3	batchnorm_1	9×1×32	offset 1×1×32
4	批量归一化;32 个通道	—	sacle 1×1×32
4	relu_1	9×1×32	—
5	maxpool_1	8×1×32	—
5	2×1 最大池化 步幅[1 1]	—	—
6	conv_2	7×1×64	weights 2×1×32×64
6	64 2×1×32 卷积 步幅[1 1]	—	bias 1×1×64
7	batchnorm_2	7×1×64	offset 1×1×64
7	批量归一化;64 个通道	—	sacle 1×1×64
8	relu_2	7×1×64	—
9	maxpool_2	3×1×64	—
9	2×1 最大池化 步幅[2 2]	—	—
10	Fc	1×1×12	weights 12×192
10	12 全连接层	—	bias 12×1
11	softmax	1×1×12	—
12	classout put	—	—

表 3 对比算法的平均诊断精度

Table 3 Average diagnostic accuracy of comparison algorithm

方法	平均诊断精度/%
DBN	99.24
ANIFS	96.74
PCA-SVM(RBF 核函数)	97.50
Koopman-CNN	99.86

### 4 结论

本文提出了一种基于 Koopman 算子纯数据驱动的模拟电路故障诊断方法,可解决模拟电路软故障诊断中由于元件参数容差性等特点,无法准确识别故障等问题。该方法通过联合仿真实现对模拟电路状态参数自动采集,利用延迟嵌入法线性化被测电路的输出响应,提取 Koopman 算子其对应的模态参数,再经过卷积核的自适应机制,通过这些模块获得层次特征来区分各种故障信号。与其他方法相比,所提方法更能够准确地对各种故障进行识别,平均诊断精度、效率更高。

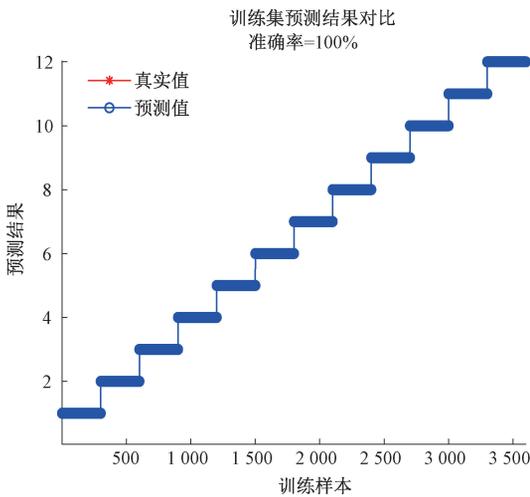


图 17 训练集预测结果

Fig. 17 Prediction results of training set

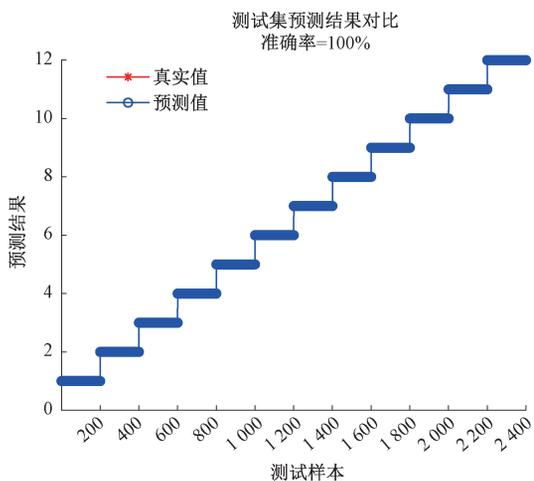


图 18 测试集预测结果

Fig. 18 Test set prediction results

未来可以从 Koopman 数据驱动的故障预测技术展开进一步的研究,即开发具有在线学习和自适应能力的 Koopman 数据驱动模型,应用于实时故障监测和预测领域,使得系统在运行时不断更新模型并根据新数据调整预测结果。

## 参考文献

- [ 1 ] SHI J, DENG Y, WANG Z, et al. A combined method for analog circuit fault diagnosis based on dependence matrices and intelligent classifiers [ J ]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(3): 782-793.
- [ 2 ] SU X, CAO C, ZENG X, et al. Application of DBN and GWO-SVM in analog circuit fault diagnosis [ J ]. Scientific Reports, 2021, 11(1): 1-14.
- [ 3 ] 杨东儒,魏建文,林雄威,等.基于自注意力机制的深度学习模拟电路故障诊断[J].仪器仪表学报,2023,44(3):128-136.  
YANG D R, WEI J W, LIN X W, et al. Deep learning analog circuit fault diagnosis based on self attention mechanism [ J ]. Chinese Journal of Scientific Instrument, 2023, 44 ( 3 ): 128-136.
- [ 4 ] ZHANG C, HE Y, YANG T, et al. An analog circuit fault diagnosis approach based on improved wavelet transform and MKELM [ J ]. Circuits, Systems, and Signal Processing, 2022, 41(3): 1-32.
- [ 5 ] JIA Z, LIU Z, GAN Y, et al. A deep forest-based fault diagnosis scheme for electronics-rich analog circuit systems [ J ]. IEEE Transactions on Industrial Electronics, 2020, 68(10): 10087-10096.
- [ 6 ] 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.
- [ 7 ] 谈恩民,沈彦飞.基于优化矩阵扰动分析的模拟电路故障诊断[J].电子测量与仪器学报,2024,38(5): 90-97.  
TAN EN M, SHEN Y F. Fault diagnosis of analog circuits based on optimization matrix perturbation analysis [ J ]. Journal of Electronic Measurement and Instrumentation, 2024, 38 ( 5 ): 90-97.
- [ 8 ] 王力,张露露.基于 IHHO-BP 神经网络的模拟电路故障诊断[J].电子测量与仪器学报,2024,38(5): 238-248.  
WANG L, ZHANG L L. Fault diagnosis of analog circuits based on IHHO-BP neural network [ J ] Journal of Electronic Measurement and Instrumentation, 2024, 38 ( 5 ): 238-248.
- [ 9 ] LU X, YANG C, WU Q, et al. Research on analog circuit soft fault diagnosis method based on mathematical morphology fractal dimension [ J ]. Electronics, 2022, 12(1): 184.
- [ 10 ] 陈晓梅,王行健,蔡焯,等.基于 AVMD 和排列熵的 t 分布邻域嵌入流形 HHO-SVM 模拟电路故障诊断方法[J].电子测量与仪器学报,2024,38(6):233-240.  
CHEN X M, WANG X J, CAI Y, et al. A t-distribution neighborhood embedding manifold HHO-SVM simulation circuit fault diagnosis method based on AVMD and permutation entropy [ J ] Journal of Electronic Measurement and Instrumentation, 2024, 38 ( 6 ): 233-240.
- [ 11 ] HANG C, SHEN Z, ZHANG J, et al. BIT-based intermittent fault diagnosis of analog circuits by improved deep forest classifier [ J ]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [ 12 ] GAO J, GUO J, YUAN F, et al. An exploration into the fault diagnosis of analog circuits using enhanced golden eagle optimized 1D-Convolutional neural network (CNN) with a time-frequency domain input and attention mechanism [ J ]. Sensors, 2024, 24(2): 20.
- [ 13 ] WANG S, LIU Z, JIA Z, et al. Composite fault diagnosis of analog circuit system using chaotic game optimization-assisted deep ELM-AE [ J ]. Measurement, 2022, 202: 111826.
- [ 14 ] XU G, LIU M, JIANG Z, et al. Online fault diagnosis method based on transfer convolutional neural networks [ J ]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(2): 509-520.
- [ 15 ] GAO T, YANG J, JIANG S, 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 ] TANG X, ZHOU X, LIANG W. Soft fault diagnosis of analog circuits based on classification of GAF\_RP images with ResNet [ J ]. Circuits, Systems, and Signal Processing, 2023, 42(10): 5761-5782.
- [ 17 ] WANG L, TIAN H, ZHANG H. Soft fault diagnosis of analog circuits based on semi-supervised support vector machine [ J ]. Analog Integrated Circuits and Signal Processing, 2021, 108(2): 305-315.
- [ 18 ] KORDA M, MEZI? I. Linear predictors for nonlinear dynamical systems: Koopman operator meets model predictive control [ J ]. Automatica, 2018, 93: 149-160.
- [ 19 ] BAKHTIARIDOUST M, YADEGAR M, MESKIN N, et al. Model-free geometric fault detection and isolation for nonlinear systems using Koopman operator [ J ]. IEEE

Access, 2022, 10: 14835-14845.

- [20] CHENG C, DING J, ZHANG Y. A Koopman operator approach for machinery health monitoring and prediction with noisy and low-dimensional industrial time series[J]. Neurocomputing, 2020, 406: 204-214.
- [21] BAKHTIARIDOUST M, YADEGAR M, MESKIN N, et al. Model-free geometric fault detection and isolation for nonlinear systems using Koopman operator [J]. IEEE Access, 2022, 10: 14835-14845.
- [22] SURANA A. Koopman operator framework for time series modeling and analysis[J]. Journal of Nonlinear Science, 2020, 30(5): 1973-2006.
- [23] LI Q, DIETRICH F, BOLLT E M, et al. Extended dynamic mode decomposition with dictionary learning: A data-driven adaptive spectral decomposition of the Koopman operator [J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 2017, 27(10): 103111.
- [24] ROWLEY C W, MEZI I, BAGHERI S, et al. Spectral analysis of nonlinear flows [J]. Journal of fluid mechanics, 2009, 641: 115-127.
- [25] KANTZ H, SCHREIBER T. Nonlinear Time Series Analysis[M]. Cambridge University Press, 2004.
- [26] JUANG J N, PAPPAS R S. An eigensystem realization algorithm for modal parameter identification and model reduction [J]. Journal of guidance, control, and dynamics, 1985, 8(5): 620-627.
- [27] 赵耀, 陆佳煜, 李东东, 等. 基于机电信号融合的电动机磁双凸极电机绕组匝间短路故障诊断[J]. 电工技术学报, 2023, 38(1): 204-219.
- ZHAO Y, LU J Y, LI D D, et al. Fault diagnosis of winding inter-turn short circuit of doubly salient electro-magnetic motor based on electromechanical signal fusion [J]. Journal of Electrotechnics, 2023, 38(1): 204-219.
- [28] 乔卉卉, 赵二贤, 郝如江, 等. 基于注意力机制与多源信息融合的变工况轴承故障诊断[J]. 仪器仪表学报, 2024, 45(9): 120-130.
- QIAO H H, ZHAO ER X, HAO R J, et al. Fault diagnosis of variable working condition bearings based on attention mechanism and multi-source information fusion [J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 120-130.
- [29] 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 for analog circuits based on time convolutional networks [J]. Electronic Measurement Technology, 2019, 42(5): 128-132.

## 作者简介



**段涛**, 2024 年于湖南师范大学获得硕士学位, 现为武汉大学电气与自动化学院博士研究生, 主要研究方向为模拟电路故障诊断、电力电子故障诊断与预测。

E-mail: duantao@whu.edu.cn

**Duan Tao** received M. Sc. degree from Hunan Normal University in 2024. Now he is a Ph. D. student at the School of Electrical and Automation of Wuhan University. His main research interests include the diagnosis of analog circuit fault, the diagnosis and prediction of electronic electrical fault.



**刘美容** (通信作者), 2009 年于湖南大学获得博士学位, 现为湖南师范大学副教授, 主要研究方向为信号处理、电路故障诊断。

E-mail: liumr12@aliyun.com

**Liu Meirong** (Corresponding author) received Ph. D. degree from Hunan University in 2009. Now she is an associate professor at Hunan Normal University. Her main research interests include signal processing and circuit fault diagnosis.



**高雄**, 现为湖南师范大学硕士研究生, 主要研究方向为模拟电路故障诊断。

E-mail: focus1323@qq.com

**Gao Xiong** is now a M. Sc. candidate at Hunan Normal University. His main research interest includes the diagnosis of analog circuit fault.



**何怡刚**, 1996 年于西安交通大学获得博士学位, 现为武汉大学教授, 主要研究方向为混合信号电路故障诊断、电子设备可靠性和通信信道建模与监测等。

E-mail: yghe1221@whu.edu.cn

**He Yigang** received his Ph. D. degree from Xi'an Jiaotong University in 1996. Now he is a professor at Wuhan University. His main research interests include the fault diagnosis of a hybrid signal circuit, the reliability of electronic equipment, and the modeling and monitoring of communication channels.