

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

陈晓梅 王行健 蔡 烨 周 博

(华北电力大学 北京 102208)

摘 要:随着信息大数据时代的到来,对于电子系统的依赖程度越来越高,因此模拟电路的故障诊断的准确度要求与日俱增。而模拟电路故障诊断困难,是电子系统诊断维修的瓶颈。本文提出基于自适应变分模态分解(AVMD)和排列熵(PE)的 t 分布邻域嵌入流形哈里斯鹰优化支持向量机(HHO-SVM)模拟电路故障诊断方法。首先,利用 AVMD 对待测电路的观测信号进行自适应变分模态分解,得到多组 IMF 信号,不仅可以克服噪声干扰,而且可以来自适应地确定分解模式的数量,进一步提升分解精度;再对 IMF 计算排列熵,以充分体现 IMF 不同时段局部特征,二者相结合构建故障特征向量。并在此基础上,采用 t 分布随机邻域嵌入(t-SNE)实现特征空间的流形学习和降维,构建具有良好区分度且保留原来的局部结构特征的故障特征向量;最后依靠哈里斯鹰优化支持向量机(HHO-SVM),使其具有良好的分类准确度,从而最终完成电路故障诊断。通过仿真验证,结果显示,本文方法故障诊断正确率可达 100%,效果良好。

关键词:自适应变分模态分解 AVMD; t 分布邻域嵌入;故障诊断;哈里斯鹰优化支持向量机

中图分类号: TN713+.8

文献标识码: A

国家标准学科分类代码: 510.1010

Analog fault diagnosis method based on AVMD and t-SNE using HHO-SVM

Chen Xiaomei Wang Xingjian Cai Ye Zhou Bo

(North China Electric Power University, Beijing 102208, China)

Abstract: In the era of information big data, the dependence degree on analog circuits is getting more severe, which results in the requirement for diagnosis accuracy of analog circuits grow with every passing day. However, analog circuits are very difficult to diagnosis, as a result, it is the bottleneck of electronic system diagnosis and maintenance. In this paper, an IHHO-SVM combining AVMD and PE and manifold learning is put forward. Firstly, adaptive variational modal decomposition AVMD is used to obtain IMF signals from observable signals of circuit under test, which could not only suppress noises disturbance, but also adaptively determine the number of IMF signals and improve the decomposition accuracy. Then IMF signals are computed with permutation entropy (PE) to construct fault features in order to fully reflect the local characteristic of IMF signal at different time span. Based on all these works, t -distributed stochastic neighbor embeddings (t-SNE) is combined to realize dimensionality reduction while remaining excellent discrimination power of fault features vectors, with the new feature vector formed at last. Finally, Harris Hawks algorithm is combined to optimize the support vector machine, which is called HHO-SVM here, for fault classification. The simulation tests show that the algorithm proposed in this paper has an excellent accuracy of 100%.

Keywords: adaptive variational modal decomposition AVMD; t -distributed stochastic neighbor embeddings; fault diagnosis; Harris Hawks optimized support vector machine

0 引 言

随着信息大数据时代的到来,许多系统更加依赖于

电子系统,其中模拟电路被广泛应用于各行各业。然而在其运行期间发生的各种故障会对此类系统造成严重影响^[1],由于模拟电路规模越来越大,且故障类型繁多,故障数据量庞大,导致模拟电路故障诊断是整个电子系统

正常运维的重要瓶颈^[2],因而成为近年来的研究热点。

纵观传统模拟电路故障诊断方法,主要有两类方法:第 1 类方法是先提前对模拟电路进行仿真,建立故障字典,然后在测量时通过提取被测电路的具体数据特征,采用类似于“查字典”的方法,找出模拟电路的故障点,典型的为故障字典法和概率统计法;第 2 类以测量得到的数据信息为依据,完成电路的模拟工作,再利用故障证实技术与参数识别技术对电路进行故障分析,归属于测后模拟。然而,传统诊断方法存在的主要问题是专家经验依赖性过强,且诊断的精度取决于模拟的精度。近年来,越来越多的研究探索利用人工智能和机器学习的方法来提高模拟电路故障诊断精度^[3-4]。

为了提高模拟电路故障诊断精度,众多研究者们主要致力于故障特征的选择,或者分类诊断模型选择优化。群智能算法由于其简单易实现、鲁棒性高且寻优能力强,日渐成为新兴人工智能算法中较为活跃的优化算法。文献[5]提出一种基于黏菌优化算法(slime mould algorithm, SMA)和极限学习机(extreme learning machine, ELM)的算法,然而 SMA 相对速度较慢;文献[6]提出了一种基于粒子群(particle swarm optimization, PSO)的流形支持向量机(support vector machine, SVM)算法,然而算法的有效性在针对所有故障数据混合的情况并未得到验证;文献[7]提出了采用多种改进方式,目的是提高粒子群算法的收敛速度和全局寻优能力,最后用性能更优的粒子群算法 IH-PSO 来优化 SVM 故障分类器,然而该算法仍然采用小波来完成特征提取过程,特征提取欠准确,另外,该算法缺少特征压缩过程,容易导致维数灾难。对于上面的粒子群算法受参数限制严重,种群多样性差,导致其容易终止于局部最优。文献[8]提出典型关联分析优化 SVM,然而算法特征加权计算之后对部分权重的舍弃过程以及特征融合方法具有较大的主观特点,均在很大程度上影响算法的效果。文献[9]提出一种利用 HHO 实现特征选择和 BP 诊断模型优化的方法,从而进一步提升诊断精度的提升。文献[10]选用神经网络作为故障分类器,采用骑手算法来实现神经网络优化,然而该方法实现的模拟电路故障诊断精度较低,这主要由于骑手算法容易陷入局部极值造成;另外,由于神经网络的训练需要的数据量大,因而导致该方法收敛速度慢、不易于实现。文献[11]提出了一种小波变换配合经改进灰狼算法优化后的 SVM 实现故障诊断的方法,然而,其故障诊断率仅能达到 90%。本文提出一种基于变分模态分解 VMD。文献[12]提出了一种将变分模态分解 VMD 和复合多尺度排列熵 CMPE 相结合来提取故障特征,然后采用麻雀算法 SSA 优化 SVM 实现故障分类。尽管该方法故障诊断效果较好,但该方法缺少故障特征压缩的过程,容易导致故障特征空间出现维数灾难,同时 SSA 算法需要的初

始参数设置较为复杂,而且 CMPE 需要首先搜寻其优化尺度,过程较为复杂。由上述分析可见, SVM 不失为一种性能优良的分类器,而变分模态分解 VMD 的特征提取更加准确;另外, t 分布式随机邻域嵌入(t-SNE)是一种重要的非线性流形学习算法,多项研究结果^[13-19]均表明,采用 t-SNE 能够实现特征空间的降维。

综上,本文提出一种基于自适应变分模式分解 AVMD 和排列熵的流形学习(分布随机邻域嵌入 t-SNE) HHO-SVM 算法,实现高精度故障诊断。该方法通过完成故障仿真和分析,确定故障类别,并得到故障数据;然后再利用 AVMD 分析方法获取故障特征,并采用流形学习(分布随机邻域嵌入 t-SNE)方法实现故障特征选择;最后,将特征选择后的最优子集作为输入,利用哈里斯鹰算法自动优化 SVM 的超参数,使其性能最优,从而实现模拟电路的故障诊断。采用典型电路(Sallen-Key 带通滤波电路和四运放双二次高通滤波器^[20])验证本文所提算法分类准确性。

1 本文算法的整体思路

本文所提出算法的整体实现思路如下:首先基于自适应变分模态分解算法 AVMD 对测量信号实现具有最优模态个数的分解,得到各个 IMF 分量;之后计算各个 IMF 分量的排列熵,得到各个故障类型对应的特征向量;然后在此基础上采用 t-SNE 在保留原始故障数据结构特征的前提下,实现原始故障数据到低维空间的映射,相当于进行了有效的特征向量压缩和降维;最后利用 HHO 优化得到的最佳超参数 c 和 g 来构成最佳分类器 SVM,完成故障分类。并用测试集完成测试,获得故障诊断率指标。本文算法的整体思路如图 1 所示。

2 本文算法的核心部分详述

2.1 自适应变分模态分解算法(AVMD)

1) 变分模态分解算法(VMD)

VMD 是将原始信号 $f(t)$ 分解为多组中心频率不相同的分量,这些分量分布被定义为在不同带宽条件下(即 IMF)。而 VMD 算法的核心步骤包括构造一个约束变分方程和求解出约束变分方程的最优解^[21]。所谓最优解,就是使得每个模态分量中心频率的带宽之和最小的 VMD 约束变分模型的极值。所构造的约束变分方程如式(1)所示:

$$\min_{\{w_k, u_k\}} \left\{ \sum_k \partial_i \left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] \| e^{-jw_k t} \|^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \quad (1)$$




图1 算法的整体思路

Fig. 1 General idea of the algorithm

式中: w_k 表示分量的中心频率; $\delta(t)$ 是冲激函数; $*$ 表示卷积操作; $u_k(t)$ 为模态函数, 即 IMF 分量经希尔伯特变换后的解析信号。

式(1)表示的就是求取“每个模态分量中心频率的带宽之和最小”时的模态函数 $u_k(t)$ 和中心频率 w_k 。

为了降低约束问题的求解难度, 引入拉格朗日因子 $\lambda(t)$ 和惩罚因子 α , 将其转换成求解相对容易的非约束问题。式(1)转换成拉格朗日非约束方程如式(2)所示:

$$L(\{u_k\}, \{w_k\}, \lambda) = \|f(t) - \sum_{k=1}^K u_k(t)\|_2^2 + \alpha \left\{ \sum_k \left\| \partial_t \left[\delta(t + \frac{j}{\pi t}) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} + \lambda(t),$$

$$f(t) - \sum_{k=1}^K u_k(t) > 0 \quad (2)$$

其中, 模态分量和中心频率分别按照式(3)和(4)进行迭代更新, 整个算法不再继续迭代的条件如式(5)所示, 其中 q 为给定一个正数, 作为判别精度:

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (3)$$

$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \quad (4)$$

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < q \quad (5)$$

当整个算法停止更新时, 原始信号在 VMD 的作用下被迭代分解成预先设定的 K 个 IMF 分量, 各个 IMF 分量的中心频率各不相同, 且所有 IMF 分量的估计带宽之和最小。

2) 自适应变分模态分解算法 AVMD

然而传统的 VMD 的 K 确定是手工设定的, K 的数目影响 IMF 分量表征信号的准确度, 从而最终影响诊断精度。AVMD 则是在分解过程不断地自动适应性调整 K 值, 使其 IMF 分量分解。AVMD 算法实现流程如图 2 所示。初始化模态分解数 $K=1$, 且设定其范围为 $[m, n]$, 设置平衡参数 a 为采样频率 F_s 的 $1/2^{[22]}$; 并设定算法结束的阈值, 这里为 0.05; 计算分解后中心频率 $w_i (i=1, 2, \dots, K)$ 相邻子信号的混叠程度系数以及各子信号与原始信号的皮尔逊相关系数 $\rho_i (i=1, 2, \dots, K)$ 。




图2 AVMD 方法的流程

Fig. 2 The flowchart for AVMD method

其中混叠程度系数的计算方法如下:

$$hd_i = |w_{i+1} - w_i| / w_i, i=1, 2, \dots, K-1;$$

皮尔逊相关系数的计算方法如下:

$$\rho_i = \frac{E(u_i - \mu_{u_i})(f - \mu_f)}{\sqrt{\sigma_{u_i}^2 \sigma_f^2}}$$

如果皮尔逊相关系数 ρ_i 大于阈值 (即 >0.05) 同时混叠程度系数 hd_j 也大于阈值 (即 >0.05), 则迭代更新 $K=K+1$, 对原始信号进行迭代变分模态分解; 如果混叠程度系数 hd_j 小于阈值 (即 <0.05) 或者皮尔逊相关系数 ρ_i 小于阈值 (即 <0.05), 以及 K 值超出最大计算范围 n , 则终

止迭代过程,输出最终确定的最优模态分解个数 K 。

2.2 t-SNE 算法

t-分布邻域嵌入(t-SNE)是一种非监督、非线性流形学习算法,它可以有效地实现高维数据的可视化降维,起源于图像处理,并广泛应用且具有良好的处理结果。t-SNE 主要实现思路是映射空间中各数据点的相对距离总是趋于维持其在原始空间的情况,也就是说,如果两个数据点在原始空间距离较近,而两个映射点距离较远,则两点就会互相吸引;反之亦然。当达到平衡时得到最后的映射,完成原始高维空间到低维空间的映射。

t-SNE 算法步骤如下:

1) 设原始高维数据空间的数据样本点为 $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$, 低维数据空间的数据样本点为 $\mathbf{y} = \{y_1, y_2, \dots, y_n\}$;

2) 初始化迭代次数、学习率和动量,在高维数据空间中任选两点 $\mathbf{x}_i, \mathbf{x}_j$, 分别按照式(6)和(7)计算它们之间的条件概率分布 p_{ji} 和 p_{ij} :

条件概率分布 p_{ji} :

$$p_{ji} = \frac{\exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / (2\sigma_i^2))}{\sum_{k \neq i} \exp(-\|\mathbf{x}_i - \mathbf{x}_k\|^2 / (2\sigma_i^2))} \quad (6)$$

条件概率分布 p_{ij} :

$$p_{ij} = \frac{\exp(-\|\mathbf{x}_j - \mathbf{x}_i\|^2 / (2\sigma_j^2))}{\sum_{k \neq j} \exp(-\|\mathbf{x}_j - \mathbf{x}_k\|^2 / (2\sigma_j^2))} \quad (7)$$

式中: σ_i, σ_j 是对应数据点 $\mathbf{x}_i$ 和点 $\mathbf{x}_j$ 的高斯分布方差;

3) 设置两数据点 $\mathbf{x}_i, \mathbf{x}_j$ 的联合概率分布 p_{ij} , 获取低维样本随机初始解 $\mathbf{y}^{(0)}$:

$$p_{ij} = \frac{p_{ji} + p_{ij}}{2}, \quad (8)$$

$$\mathbf{y}^{(0)} = \{y_1, y_2, \dots, y_n\} \quad (9)$$

$$q_{ij} = \frac{(1 + \|\mathbf{y}_i - \mathbf{y}_j\|^2)^{-1}}{\sum_{k \neq i} (1 + \|\mathbf{y}_i - \mathbf{y}_k\|^2)^{-1}} \quad (10)$$

5) 计算优化的梯度 $\frac{\partial C}{\partial \mathbf{y}_i}$:

$$\frac{\partial C}{\partial \mathbf{y}_i} = 4 \sum_j (p_{ij} - q_{ij}) (\mathbf{y}_i - \mathbf{y}_j) (1 + \|\mathbf{y}_i - \mathbf{y}_j\|^2)^{-1} \quad (11)$$

6) 根据以上公式更新输出:

$$\mathbf{y}^{(t)} = \mathbf{y}^{(t-1)} + \eta \frac{\partial C}{\partial \mathbf{y}_i} + \alpha(t) (\mathbf{y}^{(t-1)} - \mathbf{y}^{(t-2)}) \quad (12)$$

7) 循环迭代步骤 4)~6), 直到得到低维数据 $\mathbf{y}^{(T)} = \{y_1, y_2, \dots, y_n\}$, t 的范围为 $1 \sim T$ 。

2.3 HHO-SVM 优化算法

SVM 鲁棒性能良好,适用于较高维数据,能够较好地解决非线性问题,使其成为广泛采用的分类模型和回

归问题。然而 SVM 的主要局限性在于:其分类性能极其依赖良好的核函数选取,以及两个超参数取值,即惩罚因子 c 和核函数参数 g 。为此,本文提出 HHO-SVM 故障分类算法,即采用 HHO 对 SVM 的两个参数 c 和 g 进行寻优,从而使得 SVM 的分类性能得到优化提高,同时 HHO 具有很高的局部搜索能力和收敛性能,能够有效降低 SVM 的训练用时,改善诊断效率。

HHO 灵活度高,寻优策略多,是模拟自然界中哈里斯鹰狩猎行为的一种新型群智能算法,主要分为全局搜索和局部探索两个阶段。影响群智能算法性能的关键是力求实现全局搜索与局部探索二者的平衡。

1) 全局搜索

如前所述,群智能算法寻优的过程就是是全局搜索与局部探索之间平衡态的寻找过程,而这两个阶段的转变由逃逸因子 E 决定:

$$E = E_0 \cdot E_1 \quad (13)$$

$$E_0 = 2(1 - \frac{t}{T}) \quad (14)$$

式中: t 为当前的迭代次数, T 为最大迭代次数; E_0 为 $(-1, 1)$ 中的随机数,它代表每次迭代时兔子的初始能量,随迭代的进行而逐渐减小; E_1 为线性自适应因子。当 $|E| \geq 1$ 时,算法处于全局搜索阶段。在此阶段,哈里斯鹰采用两种位置更新策略:策略之一为根据兔子的位置占据据点 ($q < 0.5$),策略之二为近距离栖息 ($q \geq 0.5$)。这两种策略被赋予了相等的概率 q , $X(t+1)$ 的更新采用式(15)完成:

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 | X_{rand}(t) - 2r_2 X(t) | & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3 (LB + r_4 (UB - LB)) & q < 0.5 \end{cases} \quad (15)$$

式中: t 为当前的迭代次数, $t+1$ 则对应下一次迭代次数, $X(t)$ 为当前迭代中哈里斯鹰的位置向量, $X(t+1)$ 为下一次迭代哈里斯鹰的位置向量。 $X_{rand}(t)$ 为当前迭代从哈里斯鹰群中随机选出的哈里斯鹰个体, $X_{rabbit}(t)$ 为当前迭代兔子的位置向量,也即最优哈里斯鹰个体的位置向量。 LB 和 UB 分别为搜索空间中决策变量的上界和下界。 r_1, r_2, r_3 和 r_4 为 $(0, 1)$ 范围内的随机数。 $X_m(t)$ 为当前哈里斯鹰种群中所有成员的平均位置向量。

2) 局部搜索

当 $|E| < 1$ 时算法进入局部搜索阶段。在此过程中,首先定义一个 $(0, 1)$ 范围内的随机数 r , 作为逃跑倾向,之后,算法依据兔子的逃逸能量 E 和逃跑倾向 r , 引入 4 种策略来模拟哈里斯鹰的狩猎行为,具体如下:

策略(1) 当 $|E| \geq 0.5$ 且 $r \geq 0.5$ 时,哈里斯鹰采取策略为实施软包围,哈里斯鹰的位置更新具体实现如式

(16)~(18)所示:

$$X(t+1)=\Delta X(t)-E|J\cdot X_{rabbit}(t)-X(t)|\quad (16)$$

$$\Delta X(t)=X_{rabbit}(t)-X(t)\quad (17)$$

$$J=2(1-r_s)\quad (18)$$

式中: $\Delta X(t)$ 为当前哈里斯鹰个体与兔子之间的距离, r_s 是一个(0,1)范围内的随机数, J 表示兔子逃跑过程中的随机跳跃强度。

策略(2)当 $|E|<0.5$ 且 $r\geq0.5$ 时,认为兔子的逃逸能量不足,哈里斯鹰采取策略为硬包围策略,哈里斯鹰的位置更新具体实现如式(19)所示:

$$X(t+1)=X_{rabbit}(t)-E|\Delta X(t)|\quad (19)$$

策略(3)当 $|E|\geq0.5$ 且 $r<0.5$ 时,认为兔子具有较高的逃逸能量和逃跑倾向,哈里斯鹰采取策略为渐进式快速俯冲软包围,哈里斯鹰的位置更新具体实现如式(20)~(22)所示:

$$X(t+1)=\begin{cases}2,&F(Y)<F(X(t))\\Z,&F(Z)<F(X(t))\end{cases}\quad (20)$$

$$Y=X_{rabbit}(t)-E|JX_{rabbit}(t)-X_m(t)|\quad (21)$$

$$Z=Y+S\cdot LF(D)\quad (22)$$

式中: S 为大小为 $1\times D$ 的随机列表, D 为变量维度, F 为适应度函数, LF 为levy飞行函数,用于模拟哈里斯鹰在狩猎期间快速、突然和不规则的移动。

策略(4)当 $|E|<0.5$ 且 $r<0.5$ 时,哈里斯鹰采用策略为渐进式快速俯冲硬包围,哈里斯鹰的决策机制与式(8)相同,哈里斯鹰更新位置 Y 如式(23)所示:

$$Y=X_{rabbit}(t)-E|JX_{rabbit}(t)-X_m(t)|\quad (23)$$

总之,哈里斯鹰算法最终优化结果是得到种群中最优哈里斯鹰个体的位置 $X_{rabbit}(t)$,分别对应 SVM 的惩罚因子 c 和核函数参数 g 。

3 仿真实验

为例验证本文所提出算法的有效性,采用国际上通行的两个电路^[21]进行验证:Sallen-Key 带通滤波器和四运放双二次高通滤波器。

3.1 实例 1

本仿真验证实例采用典型的 Sallen-Key 带通滤波器,其电路图如图 3 所示。这里考虑纯软故障,为此,需要对各个电路元件参数完成蒙特卡洛分析。首先,需设定电路中各元件参数值的元件标称值,具体设置如图 3 所示。将电路中电阻类型的元件容差设为:电阻 $\pm 5\%$,将电容类型的元件容差设为 $\pm 10\%$ 。并且假设电路发生软故障的判定条件为当元件参数偏离标称值 50%。具体而言,软故障又可以分为元件参数增大的故障元件参数减小的故障。假设电路中 R_2,R_3,C_1,C_2 分别发生参数增大和减小的故障,则电路的状态可以划分为正常状态(F0:

NF)和 8 种故障状态(F1: R_2 增大;F2: R_2 减小;F3: R_3 增大;F4: R_3 减小;F5: C_1 增大;F6: C_1 减小;F7: C_2 增大;F8: C_2 减小)^[21]。




图 3 Sallen-Key 带通滤波器的典型电路原理
Fig. 3 Sallen-Key bandpass filter schematic

在 Cadence 17 中对上述各种故障类别分别进行 100 次 Monte Carlo 分析,采集 120 μ s 内的输出端波形并保存作为电路输出数据。9 种故障共 900 个样本,从种随机抽取 300 个样本作为训练集,剩余 600 个样本作为测试集,所施加激励信号参数具体设置如图 3 所示。

采用 4 种算法进行验证对比,其详细的,其运行的故障诊断正确率如下表 1 所示。为了排除各部分初值参数的影响,表中故障正确率是连续运行 10 次取平均值的结果。图 4 为故障分类结果图,可见其故障诊断正确率为 100%。

表 1 Sallen-Key 带通滤波器电路故障
诊断各算法运行结果对比

Table 1 Sallen-Key bandpass filter fault diagnosis algorithm comparison				
文献	特征提取	特征选择	分类器	故障正确率/%
比对算法 1	小波包	PCA	HHO_SVM	81
比对算法 2	小波包	t-SNE	HHO_SVM	97.2
文献[11]	VMD+CMPE	-	SSA_SVM	99.67
本文算法	AVDM+PE	t-SNE	HHO_SVM	100

3.2 实例 2

四运放双二次高通滤波器的典型电路如图 5 所示。电路中各个元件及对应标称值的详细参数设置如图 5 所示,相应地,将电路中电阻类型的元件容差设为:电阻 $\pm 5\%$,将电容类型的元件容差设为 $\pm 10\%$ 。并且假设电路发生软故障的判定条件为当元件参数偏离标称值 50%。电路中故障类别分别为:F1~F12 分别对应 C_1,C_2,R_1,R_2,R_3,R_4 参数增大和减小时的故障,F0 为电路正常状态(NF)^[21]。同样,为了模拟电路的软故障,每个故障进行 200 次 Monte Carlo 分析。每个故障抽取前 100 个样本组成训练集,后 100 个样本组成测试集。

采用 4 种算法进行验证对比,其详细的,其运行的故障诊断正确率如表 2 所示。为了排除各部分初值参数的




图 4 本文算法对 Sallen-Key 带通滤波器故障分类结果
Fig. 4 Sallen-Key bandpass filter fault classification




图 6 本文算法对四运放双二次高通滤波器的故障分类结果
Fig. 6 Quad-operational-amplifier double highpass filter fault classification




图 5 四运放双二次高通滤波器典型电路原理
Fig. 5 Quad-operational-amplifier double highpass filter schematic

影响,表中故障正确率是连续运行 10 次取平均值的结果。图 6 为故障分类结果图,可见其故障诊断正确率为 100%。

表 2 四运放双二次高通滤波器对应的故障
诊断各算法运行结果比较

Table 2 Quad-operational-amplifier double highpass filter fault diagnosis algorithm comparison				
文献	特征提取	特征选择	分类器	诊断正确率/%
比对算法 1	小波包	PCA	HHO_SVM	78
比对算法 2	小波包	t-SNE	HHO_SVM	96
文献[11]	VMD+CMPE	-	SSA_SVM	99.67
本文算法	AVDM+PE	t-SNE	HHO_SVM	100

四运放双二次高通滤波器的原始故障数据经过 AVMD 分解和排列熵提取特征向量之后,采用流形学习方法 t-SNE 进行降维之后的特征数据分类散点图如图 7 所示,从图可发现,t-SNE 在进行降维的同时,仍然尽可能地保留了原始故障数据的结构特点,不同故障类型的

样本汇聚成不同的簇,簇内各样本点距离很小,簇间各样本点则距离较大。这也说明该方法是一种可行的模拟电路故障特征数据降维方法,上面两个实例的诊断结果也验证了该流形学习方法能够显著改善模拟电路故障诊断效率。




图 7 四运放双二次高通滤波器电路原始
数据 t-SNE 降维后的散点图
Fig. 7 Quad-operational-amplifier double highpass filter original data t-SNE dimension reduction scatter plot

4 结 论

针对模拟电路中难以辨识的软故障诊断,本文提出了 AVMD 和 PE 的 t 分布邻域嵌入 HHO-SVM 模拟电路故障诊断方法。利用 AVMD 和 PE 提取信号特征,能够确保在实现最优模态分解的基础上,实现特征提取;之后采用 t-SNE 算法实现特征降维,可以在保留原始特征数据结构特点的同时,将高维特征数据映射到低维空间中,从而形成非常理想的具有良好的可区分度的特征向量。

基于 HHO-SVM 的分类网络能够改善普通 SVM 网络的性能,能够利用 HHO 算法实现 SVM 超参数的优化,使得 SVM 具有优良的分类性能。运行 10 次取平均值,整体诊断精度达到了 100%。由此可见,本文算法具有极强的稳定性。

参考文献

- [1] JI L, HU X. Analog circuit soft-fault diagnosis based on sensitivity analysis with minimum fault number rule[J]. *Analog Integrated Circuits and Signal Processing*, 2018, 95: 163-171.
- [2] 谈恩民,李峰. 结合 LMD 云模型和 ABC-LSSVM 的模拟电路故障诊断[J]. *电子测量与仪器学报*, 2020, 34(2): 80-87.
- TAN EN M, LI F. Analog circuit fault diagnosis combined with LMD cloud model and ABC-LSSVM[J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(2): 80-87.
- [3] ARABI A, AYAD M, BOUROUBA N, et al. An efficient method for faults diagnosis in analog circuits based on machine learning classifiers[J]. *Alexandria Engineering Journal*, 2023, 77: 109-125.
- [4] 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. 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] 林知微,王成吉,刘宗朋,模拟电路中黏菌算法优化 ELM 故障诊断模型研究[J]. *传感器与微系统*, 2023, 42(6): 47-50.
- LIN ZH W, WANG CH J, LIU Z P. Research on slime mould algorithm optimized ELM fault diagnosis model in analog circuit[J]. *Transducer and Microsystem Technologies*, 2023, 42(6): 47-50.
- [6] 单剑锋,杨雨. 粒子群优化的流形 SVM 模拟电路故障诊断[J]. *机械科学与技术*, 2019, 38(2): 260-264.
- SHAN J F, YANG Y. Fault diagnosis of manifold SVM analog circuit based on particle swarm optimization[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2019, 38(2): 260-264.
- [7] YUAN X, LIU Z, MIAO Z, et al. Fault diagnosis of analog circuits based on IH-PSO optimized support vector machine[J]. *IEEE Access*, 2019, 7: 137945-137958.
- [8] LI Y, ZHANG R, GUO Y, et al. Nonlinear soft fault diagnosis of analog circuits based on RCCA-SVM[J]. *IEEE Access*, 2020, 8: 60951-60963.
- WANG L, ZHANG L L. Fault diagnosis of analog circuit based on IHHO-BP neural network[J/OL]. *Journal of Electronic Measurement and Instrumentation*, 1-13[2024-05-13]. <http://kns.cnki.net/kcms/detail/11.2488.TN.20221128.1339.008.html>.
- [9] 王力,张露露. 基于 IHHO-BP 神经网络的模拟电路故障诊断[J/OL]. *电子测量与仪器学报*, 1-13[2024-05-13]. <http://kns.cnki.net/kcms/detail/11.2488.TN.20221128.1339.008.html>.
- WANG L, ZHANG L L. Fault diagnosis of analog circuit based on IHHO-BP neural network[J/OL]. *Journal of Electronic Measurement and Instrumentation*, 1-13[2024-05-13]. <http://kns.cnki.net/kcms/detail/11.2488.TN.20221128.1339.008.html>.
- [10] BINU D, KARIYAPPA B S. RideNN: A new rider optimization algorithm-based neural network for fault diagnosis in analog circuits[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 68(1): 2-26.
- [11] 熊魁,岳长喜,刘冬梅,等. 基于 IGWO 算法优化的 SVM 模拟电路故障诊断[J]. *微电子学与计算机*, 2019, 36(1): 16-21.
- XIONG K, YUE CH X, LIU D M, et al. Analogue circuit fault diagnosis based on SVM optimized by IGWO[J]. *Microelectronics & Computer*, 2019, 36(1): 16-21.
- [12] 刘沛霖,刘美容,何怡刚,等. 基于改进的 VMD 和 SVM 的模拟电路故障诊断方法的研究[J]. *微电子学与计算机*, 2022, 39(11): 85-94.
- LIU P L, LIU M R, HE Y G, et al. Research on fault diagnosis method based on improved VMD and SVM[J]. *Microelectronics & Computer*, 2022, 39(11): 85-94.
- [13] 殷秀丽,谢丽蓉,杨欢,等. 特征选择与 t-SNE 结合的滚动轴承故障诊断[J]. *机械科学与技术*, 2023, 42(11): 1784-1793.
- YIN X L, XIE L R, YANG H, et al. Rolling bearing fault diagnosis combined feature selection with t-distributed stochastic neighbor embedding[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2023, 42(11): 1784-1793.
- [14] 柳守诚,王淳,邹智辉,等. 基于 t-SNE 降维和放射传播聚类算法的低压配电网相位识别[J]. *中国电力*, 2023, 56(5): 108-117.
- LIU SH CH, WANG CH, ZOU ZH H, et al. Phase identification of low voltage distribution network based on t-SNE dimension reduction and affinity propagation clustering algorithm[J]. *Electric Power*, 2023, 56(5): 108-117.
- [15] 张淑清,段晓宁,张立国,等. Tsne 降维可视化分析及飞蛾火焰优化 ELM 算法在电力负荷预测中应用[J]. *中国电机工程学报*, 2021, 41(9): 3120-3130.

- ZHANG SH Q, DUAN X N, ZHANG L G, et al. Tsne dimension reduction visualization analysis and moth flame optimized ELM algorithm applied in power load forecasting [J]. Proceedings of the CSEE, 2021, 41(9): 3120-3129.
- [16] 姜战伟,郑近德,潘海洋,等. 基于多尺度时不可逆与 t-SNE 流形学习的滚动轴承故障诊断[J]. 振动与冲击, 2017, 36(17): 61-68, 84.
- JIANG ZH W, ZHENG J D, PAN H Y, et al. Rolling bearing fault diagnosis method based on multiscale time irreversibility and t-SNE manifold learning[J]. Journal of Vibration and Shock, 2017, 36(17): 61-68, 84.
- [17] HU H, GUO J, WU Y, et al. t-SNE dimensionality reduction method based on Sobol sequence initialized archerfish hunting optimizer algorithm [C]. 2022 7th International Conference on Computational Intelligence and Applications (ICCIA). IEEE, 2022: 43-47.
- [18] GARE S, CHEL S, KURUBA M, et al. Dimension reduction and clustering of single cell calcium spiking: comparison of t-SNE and UMAP [C]. 2021 National Conference on Communications (NCC). IEEE, 2021: 1-6.
- [19] GONG F, SHEN Y, QIAO L, et al. A dimensional reduction visualization method for large data of power grid based on t-SNE algorithms [C]. 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP). IEEE, 2019: 1-5.
- [20] 朱静,何玉珠,崔唯佳. 正弦余弦算法优化的 SVM 模拟电路故障诊断[J]. 导航与控制, 2018, 17(4): 33-40.
- ZHU J, HE Y ZH, CUI W J. Analog circuit fault diagnosis based on SVM optimized by SCA [J]. Navigation and Control, 2018, 17(4): 33-40.
- [20] WANG Y, ZHANG M K, TANG X W, et al. A kMap optimized VMD-SVM model for milling chatter detection with an industrial robot [J]. Journal of Intelligent Manufacturing, 2022, 33(5): 1483-1502.
- [21] 郑近德,潘海洋,杨树宝,等. 广义变分模态分解方法及其在变工况齿轮故障诊断中的应用[J]. 振动工程学报, 2017, 30(3): 502-509.
- ZHENG J D, PAN H Y, YANG SH B, et al. Generalized variational mode decomposition and its applications to gearbox fault diagnosis under variable conditions [J]. Journal of Vibration Engineering, 2017, 30(3): 502-509.
- [22] WANG Y, ZHANG M K, TANG X W, et al. A kMap optimized VMD-SVM model for milling chatter detection with an industrial robot [J]. Journal of Intelligent Manufacturing, 2022, 33(5): 1483-1502.

作者简介



陈晓梅 (通信作者), 2010 年于北京航空航天大学获得博士学位, 现为华北电力大学电气学院副教授, 主要研究方向为电子系统可靠性与维修。

E-mail: chxm@ncepu.edu.cn

Chen Xiaomei (Corresponding author) received her Ph. D. degree from Beihang University in 2010. Now she is an associate professor in North China Electric Power University. Her main research interests include electronic system reliability and maintenance.