

DOI: 10.19650/j.cnki.cjsi.J1905283

基于 DBN 特征提取的模拟电路早期故障诊断方法*

张朝龙^{1,2}, 何怡刚¹, 杜博伦¹

(1. 武汉大学电气与自动化学院 武汉 430072; 2. 安庆师范大学物理与电气工程学院 安庆 246011)

摘要:针对当前模拟电路早期故障诊断中特征提取方法的不足,提出了应用深度置信网络(deep belief network, DBN)进行特征提取的方法。利用混沌粒子群优化算法,对 DBN 中受限玻尔兹曼机的学习率开展优化,进一步提升特征提取的性能。相比于其他常用的特征提取方法,提出的 DBN 特征提取方法可提取出早期故障深度和本质的特征,且具有相同的故障聚集程度高、不同故障的分离能力极为明显的特点。应用二级四运放双二阶低通滤波器仿真电路和 Sallen-Key 带通滤波器电路板进行早期故障诊断实验,得到的故障诊断正确率分别为 98.13% 和 100%。

关键词:模拟电路;早期故障诊断;深度置信网络;特征提取;混沌粒子群优化

中图分类号: TH707 **文献标识码:** A **国家标准学科分类代码:** 510.1010

Analog circuit incipient fault diagnosis method based on DBN feature extraction

Zhang Chaolong^{1,2}, He Yigang¹, Du Bolun¹

(1. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China;

2. School of Physics and Electronic Engineering, Anqing Normal University, Anqing 246011, China)

Abstract: Aiming at the deficiency of current feature extraction methods of analog circuit incipient fault diagnosis, the feature extraction method applying deep belief network (DBN) technology is presented. Chaos particle swarm optimization (CPSO) algorithm is employed to optimize the learning rates of the restricted Boltzmann machines in DBN and further improve the feature extraction performance. Compared with other commonly used feature extraction methods, the proposed DBN feature extraction method can extract the deep and essential features of incipient faults. The proposed method also has the features, such as the same high fault aggregation degree and obvious different fault separation capacity. Two-stage four-op-amp biquad lowpass filter simulation circuit and Sallen-Key bandpass filter circuit board were used to carried out incipient fault diagnosis experiments, and the obtained fault diagnosis accuracies are 98.13% and 100%, respectively.

Keywords: analog circuit; incipient fault diagnosis; deep belief network (DBN); features extraction; chaos particle swarm optimization (CPSO)

0 引 言

模拟电路广泛地应用于各类智能仪表中,执行信号产生、信号放大、信号转换以及运算等功能。模拟电路的故障将影响智能仪表的性能,具体表现为仪表功能减弱或失效。因此,针对模拟电路故障诊断问题,当前许多课题组均开展了卓有成效的研究^[1-10]。

在模拟电路的故障诊断研究中,模拟电路早期故障诊断的研究引起了研究者的重视^[9-10]。模拟电路的早期故障是指电路的元件参数值已经偏离了正常的容差范围,但尚未发展至故障阈值,此时电路的输出发生了偏差,具有功能失效的危险。对早期故障进行诊断,可进一步地预测该模拟电路的故障时间,进而计算电路的剩余有用性能。由于元件早期故障参数值与元件正常容差范围差距不大,故各元件早期故障特征与元件正常状态特

收稿日期:2019-06-20 Received Date:2019-06-20

* 基金项目:国家自然科学基金(51607004,51977153,51577046)、国家自然科学基金重点项目(51637004)、国家重点研发计划“重大科学仪器设备开发”(2016YFF0102200)、装备预先研究重点项目(41402040301)资助

征之间区别不明显,各个不同早期故障之间,以及各个早期故障和正常状态之间易于发生特征的重叠,不利于早期故障的准确识别。因此在模拟电路早期故障诊断中,首要问题是提取出故障固有、本质且重叠程度低的特征。

在模拟电路故障诊断的特征提取过程中,首先给予被测电路激励信号,然后将输出端测量响应信号作为原始数据,最后应用各类信号分析方法处理原始数据从而生成特征。小波变换^[3-5]、峭度和熵^[6]、小波分形分析^[7-8]等方法已应用于模拟电路故障诊断的特征提取,其中尤其以小波变换的应用最为广泛。然而,信号分析方法在提取特征时易于忽略信号中的有用信息,以及在提取的特征中附加了冗余信息。因此,在应用于模拟电路早期故障的特征提取时,难以提取深度和本质特征,且提取的特征易于发生重叠。深度置信网络(deep belief network, DBN)是由多个受限玻尔兹曼机(restricted Boltzmann machine, RBM)构成的深度学习方法^[11],利用多层无监督学习和有监督微调,可提取信号的本质和固有特征^[12-14]。当前有研究工作将 DBN 应用于模拟电路故障特征提取^[15],然而该研究工作在建立 DBN 网络结构和更新网络权值的过程中,使用经验法设定 RBM 的学习率,因此需要多次尝试且较难达到最好的特征提取效果。

分类方法的研究是故障诊断中另一个关键问题。人工神经网络是模拟神经元网络的机器学习方法,在经典的故障诊断工作中得到了应用^[2, 6-7],该方法的缺点为收敛速度慢和过拟合等。支持向量机(support vector machine, SVM)是当前应用广泛的分类方法^[16],利用核函数的非线性映射特点分类非线性数据,尤其是小样本数据,在模拟电路故障诊断中得到了一致的认可^[1, 4]。广义多核支持向量机(generalized multiple kernel learning-support vector machine, GMKL-SVM)针对 SVM 的核函数进一步优化^[3],利用 L_1 -MKL 和 L_2 -MKL 共同管理核函数,并生成各个基础核函数的稀疏解。 L_1 -MKL 和 L_2 -MKL 比例关系由算法中的折衷参数分配,而 SVM 中惩罚因子为关键参数,因此,需要通过适当的方法对折衷参数和惩罚因子进行优化,从而提升 GMKL-SVM 的诊断性能。

混沌粒子群优化(chaos particle swarm optimization, CPSO)算法是在粒子群算法^[17]中引入混沌优化算法,从而提高粒子的随机性和遍历性,在参数寻优中效果显著^[18-19]。在此,针对模拟电路早期故障诊断中的难点,本文有针对性地提出了应用 DBN 进行特征提取,GMKL-SVM 进行早期故障诊断和 CPSO 进行参数寻优的诊断方法。在本方法中,针对各个早期故障类别的信号数据,应用 DBN 方法提取深层次特征,其中 DBN 中 RBM 的学习率应用 CPSO 方法优化生成,具有相同故障特征聚集更

加紧密,不同故障特征之间区别更加明显的优点,相比经验设定法,可表现出更好的特征提取效果。基于特征数据,建立 GMKL-SVM 的早期故障诊断模型,其中 GMKL-SVM 的惩罚因子和折衷参数由 CPSO 算法优化获得。最后,应用二级四运放双二阶低通滤波器仿真电路和 Sallen-Key 带通滤波器电路板对提出的 DBN 特征提取方法和 GMKL-SVM 故障诊断模型的性能进行了测试。

1 基于 DBN 的特征提取方法

DBN 是一种将无监督和有监督相结合的深度学习方法^[11],由多个 RBM 堆叠构成,一般在尾部连接 1 个 Softmax 分类器。

1.1 RBM

RBM 包括 1 个可见层 \mathbf{v} 和 1 个隐藏层 \mathbf{h} , 设 $\mathbf{v} = \{0, 1\}^D$, $\mathbf{h} = \{0, 1\}^K$ 。参照可见层 \mathbf{v} 、隐藏层 \mathbf{h} 重构 \mathbf{v}^* , 故将隐藏层 \mathbf{h} 中的信息提取, 作为输入可见层 \mathbf{v} 的信号的特征。

首先, 设定 RBM 中单元联合配置的能量:

$$E(\mathbf{v}, \mathbf{h}) = - \sum_{i=1}^D \sum_{j=1}^K v_i w_{ij} h_j - \sum_{j=1}^K a_j h_j - \sum_{i=1}^D b_i v_i \quad (1)$$

式中: w_{ij} 、 b_i 、 a_j 是重要的结构参数, 分别表示连接权重、可见层单元和隐含层单元的偏置。

\mathbf{v} 和 \mathbf{h} 的条件分布为:

$$p(h_j = 1 | \mathbf{v}) = \sigma \left(\sum_i W_{ij} v_i + b_j \right) \quad (2)$$

$$p(v_i = 1 | \mathbf{h}) = \sigma \left(\sum_j W_{ij} h_j + a_i \right) \quad (3)$$

式中: σ 为激活函数。

w_{ij} 在此依据对比散度法进行调整:

$$\Delta w_{ij} = r(v_i h_{j, \text{data}} - v_i h_{j, \text{reconstruction}}) \quad (4)$$

式中: r 是 RBM 的学习率, 在 DBN 中各个连接权重的更新和多层网络结构的确定中发挥重要的作用。

1.2 DBN 方法的特征提取过程

可将 DBN 方法的特征提取过程分为两个阶段: 预训练阶段和微调阶段。在预训练阶段, 将训练数据输入 DBN 的第 1 个 RBM, 开展无监督的训练, 训练结束后将第 1 个 RBM 的输出作为下一个 RBM 的输入, 依此方案反复执行, 直到最后一个 RBM 训练完毕, 从而形成了一个无监督学习的 DBN 特征提取模型。在全局微调阶段, 基于训练数据的类别信息, 对比 Softmax 分类器判定的类别, 统计识别错误, 并利用反向传播算法对 DBN 网络反向训练, 微调各个初始连接权重, 进一步地减少再次诊断时的误差数。全局微调阶段可以进一步地优化 DBN 网络中各个连接权重, 有利于 DBN 提取更为本质和固有的特征。微调结束后, 最后一个 RBM 提取的特征即为 DBN 提取的特征。

2 GMKL-SVM

支持向量机中数据集 D 为 $\{x_i, y_i\}_{i=1}^N$, 通过建立决策函数 f 分类未知数据:

$$f^* = \operatorname{argmin}_f CR_{\text{emp}}(f) + \Omega(f) \quad (5)$$

式中: $R_{\text{emp}}(f)$ 是 f 的经验风险; C 是惩罚因子。

核函数 $K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$ 将输入数据映射至一个 Hilbert 空间, 则决策函数式(5)替换为:

$$f(x) = \sum_{i=1}^N a_i^* K(x, x_i) + b^* \quad (6)$$

式中: a^* 和 b^* 通过计算式(5)中优化的对偶问题获得。

在多核学习方法中组合 M 个核函数, 决策函数式(5)则可表示为:

$$f_{\hat{w}, b, u}(x) = \hat{w}^T \phi_u(x) + b = \sum_{m=1}^M \sqrt{u_m} w_m^T \phi_m(x) + b \quad (7)$$

式中: $\hat{w} = (w_1^T, \dots, w_M^T)^T$ 是权重; $\phi_u = \sqrt{u_1} \phi_1 \times \dots \times \sqrt{u_M} \phi_M$; u_m 是 K_m 的系数, 核函数一般应用高斯核函数和多项式核函数的组合。

GMKL 方法参考 L_1 -MKL 方法和 L_2 -MKL 方法的优点约束多核核函数系数:

$$\min_{u \in \Theta, \hat{v}, b} C \sum_{i=1}^N R(f_{\hat{v}, b}(x_i), y_i) + \frac{1}{2} \sum_{m=1}^M \frac{v_m^T v_m}{u_m} \quad (8)$$

其中, v_m 定义为 $\sqrt{u_m} w_m$, $\hat{v} = (v_1^T, \dots, v_M^T)^T$, $f_{\hat{v}, b}(x_i) = \sum_{m=1}^M v_m^T \phi_m(x) + b$, 且 u 的域为:

$$\Theta = \{u \in \mathbf{R}_+^M; z \|u\|_1 + (1-z) \|u\|_2^2 \leq 1\} \quad (9)$$

式中: $z \in [0, 1]$, 是折衷参数, 用于分配约束项的比例。

引入了松弛变量 ξ_i 后的优化问题可表示为:

$$\min_{u \in \Theta} \min_{\hat{v}, b, \xi} C \sum_{i=1}^N \xi_i + \frac{1}{2} \sum_{m=1}^M \frac{v_m^T v_m}{u_m} \quad (10)$$

s.t. $y_i \left(\sum_{m=1}^M v_m^T \phi_m(x_i) + b \right) \geq 1 - \xi_i, \xi_i \geq 0$

GMKL-SVM 的分类性能受算法中惩罚因子和折衷参数的影响较大, 在此, 采用 CPSO 算法优化惩罚因子和折衷参数。

3 基于 CPSO 算法的参数寻优

粒子群算法是一种仿生优化算法, 它通过模仿鸟类的觅食行为进行参数寻优^[17]。CPSO 的算法在粒子群算法的执行过程, 引入混沌优化算法, 从而提高粒子的随机性和遍历性^[18-19]。本文采用 CPSO 算法对 DBN 中 RBM 的学习率以及 GMKL-SVM 中的惩罚因子和折衷参数进行寻优。

3.1 CPSO 算法

粒子位置和速度的进化方程分别为:

$$V_i(t+1) = wV_i(t) + c_1 r_1 (P_i - X_i(t)) + c_2 r_2 (P_g - X_i(t)) \quad (11)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (12)$$

式中: c_1 和 c_2 为加速因子; w 是惯性权重, 用于调节速度; r_1 和 r_2 为随机数, 取值于 0~1 之间; P_i 和 P_g 分别为个体最优位置和全局最优位置。

PSO 算法中个体最优位置的选择方法如下:

$$P_i = \begin{cases} P_i, & f(P_i) \geq f(X_i(t+1)) \\ X_i(t+1), & f(P_i) < f(X_i(t+1)) \end{cases} \quad (13)$$

整个粒子群的全局最优位置选举方法为:

$$P_g(t) = \operatorname{argmax} \{f(P_i)\} \quad (14)$$

在此应用的混沌算法是 Logistic 映射:

$$Z_{n+1} = \mu Z_n (1 - Z_n) \quad \mu \in [0, 4] \quad (15)$$

式中: μ 为映射参数; Z_n 和 Z_0 分别为混沌变量及其初始值。

CPSO 算法针对全局最优位置应用混沌算法遍历寻优空间, 获取新的位置并将位置随机地赋予种群中的一个粒子。CPSO 算法的随机性和遍历性, 有助于其克服粒子群算法局部最优和收敛性差的缺点, 从而获得更好的参数寻优结果。

3.2 参数优化方法

DBN 中 RBM 的学习率以及 GMKL 中的惩罚因子和折衷参数, 分别应用 CPSO 算法优化。在 DBN 中 RBM 学习率的优化中, 粒子寻优的位置即为学习率, 其中粒子位置的维数等于待优化的学习率数量, 优化的步骤如下。

1) 初始化 CPSO 算法;

2) 计算各个粒子的适应度, 方法为将粒子的每一维位置作为 DBN 中一个 RBM 的学习率, 基于测量的信号数据, 应用 DBN 的堆叠 RBM 和 Softmax 分类器, 开展特征提取和故障识别, 以正确率为适应度;

3) 通过式(13)得出各个粒子的个体最优位置, 并通过公式(14)推选出全局最优位置;

4) 利用式(11)和(12), 改变每个粒子的位置和速度;

5) 基于式(15), 混沌优化全局最优位置, 并生成新的位置随机地赋予种群中的一个粒子;

6) 重复执行步骤 2)~5), 直到算法结束;

7) 将全局最优位置作为本次寻优的结果, 即为 DBN 中各个 RBM 的学习率。

在 DBN 中 RBM 的学习率优化完成后, 即可应用 DBN 提取特征。基于提取的特征数据, 对 GMKL-SVM 中的惩罚因子和折衷参数进行优化, 将两个参数分别映射为 CPSO 算法中每个粒子 2 维位置中的 1 维, 优化的步

骤如下。

- 1) 初始化 CPSO 算法;
- 2) 计算各个粒子的适应度,方法为将粒子的 2 维位置映射为 GMKL-SVM 的惩罚因子和折衷参数,针对特征数据开展故障识别,以正确率作为适应度;
- 3) 通过式 (13) 得出各个粒子的个体最优位置,并通过式 (14) 推选出全局最优位置;
- 4) 利用式 (11) 和 (12),改变每个粒子的位置和速度;
- 5) 基于式 (15),混沌优化全局最优位置,并生成新的位置随机地赋予种群中的一个粒子;
- 6) 重复执行步骤 2)~5),直到算法结束;
- 7) 将全局最优位置作为本次寻优的结果,即为 GMKL-SVM 的惩罚因子和折衷参数。

基于早期故障的训练数据,GMKL-SVM 的惩罚因子和折衷参数由 CPSO 算法优化生成,该 GMKL-SVM 可用于识别早期故障。

4 仿真实验及分析

图 1 所示为本文提出的早期故障诊断方法的实验过程,分为以下 5 个步骤。

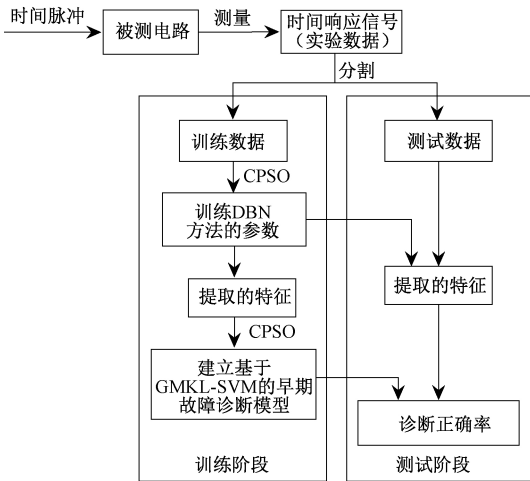


图 1 本文提出的诊断流程

Fig.1 The diagnosis flow chart proposed in the paper

- 1) 设定各个早期故障,测量输出响应信号作为实验数据,并分割为训练数据和测试数据;
- 2) 初始化 DBN,通过训练数据提取各个早期故障类别的特征,其中 DBN 中 RBM 的学习率通过 CPSO 算法优化;
- 3) 基于 GMKL-SVM 方法,应用提取的特征构建早期故障诊断模型,其中 GMKL-SVM 的惩罚因子和折衷参数应用 CPSO 算法优化;
- 4) 利用建立的 DBN 方法和 GMKL-SVM 诊断模型,对测试数据开展早期故障识别;

5) 计算诊断正确率,从而鉴定 DBN 特征提取方法和 GMKL-SVM 诊断模型的性能。

4.1 早期故障诊断示例

图 2 所示为二级四运放双二阶低通滤波器原理图,以此仿真电路的早期故障诊断为示例,展示提出的早期故障诊断方法。以 $10 \mu\text{s}$ 持续时间和 10 V 幅值的脉冲信号为电路输入,并在电路输出端采集响应信号。电阻和电容的容差设置为 5%。一般元件的参数性故障定义为当元件参数值偏离标称值 50% 时,即可判定该元件发生故障^[1-10],本文定义早期故障为元件参数值偏离标称值在 5%~25% 之间。本次实验设定单个元件发生早期故障,而其他元件的参数值在容差范围内随机变化。通过灵敏度测试,测试对象选用 R4、R6、R7、R9、R18、C1 和 C4,表 1 所示为测试元件的各项参数,其中 NF 为无故障,↑和↓表示参数值升高和降低。

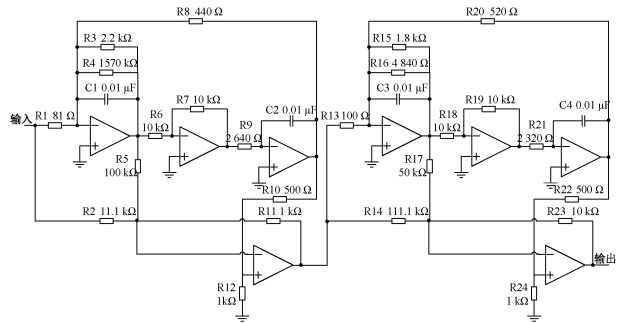


图 2 二级四运放双二阶低通滤波器

Fig.2 Two-stage four-op-amp biquad lowpass filter

表 1 低通滤波器中各测试元件的参数

Table 1 The parameters of the test components in lowpass filter

早期故障码	早期故障类别	标称值	早期故障值
F0	NF	-	-
F1	R4 ↑	1 570 Ω	1 648.5~1 962 Ω
F2	R4 ↓	1 570 Ω	1 176~1 491.5 Ω
F3	R6 ↑	10 kΩ	10.5~12.5 kΩ
F4	R6 ↓	10 kΩ	7.5~9.5 kΩ
F5	R7 ↑	10 kΩ	10.5~12.5 kΩ
F6	R7 ↓	10 kΩ	7.5~9.5 kΩ
F7	R9 ↑	2 640 Ω	2 772~3 300 Ω
F8	R9 ↓	2 640 Ω	1 980~2 508 Ω
F9	R18 ↑	10 kΩ	10.5~12.5 kΩ
F10	R18 ↓	10 kΩ	7.5~9.5 kΩ
F11	C2 ↑	0.01 nF	0.010 5~0.012 5 nF
F12	C2 ↓	0.01 nF	0.007 5~0.009 5 nF
F13	C4 ↑	0.01 nF	0.010 5~0.012 5 nF
F14	C4 ↓	0.01 nF	0.007 5~0.009 5 nF

应用蒙特卡洛方法采样获得 100 维响应信号,直接输入 DBN 中第 1 个 RBM 的可视层。由于双隐含层结构对计算资源占用不大且计算效果较好,故得到了广泛的应用,本文同样采用双隐含层结构构建 DBN。可视层和第 1 个隐含层构成了第 1 个 RBM,第 1 个和第 2 个隐含层构成了第 2 个 RBM,两个隐含层的单元数量分别被设置为 50 和 25,因此,DBN 的最终提取的特征维度为 25。分别对每个早期故障类别采集 100 个数据,故共有 1 500 个实验数据。每个早期故障类别的 100 个数据中,随机选择 50 个作为训练数据,共 750 个数据用于优化获取 DBN 中的 RBM 的学习率,并生成特征数据用于训练基于 GMKL-SVM 的早期故障诊断模型。剩余 750 个数据为测试数据,用于评价 DBN 特征提取方法和 GNKL-SVM 诊断模型的性能。

CPSO 算法中,设定粒子的数量为 10 个,进化代数数为 100 代,Logistic 映射参数设置为 4,用于优化获得两个 RBM 的学习率。经计算,优化生成的第 1 个 RBM 和第 2 个 RBM 的学习率分别为 0.012 513 532 183 446 和 0.014 739 445 666 037。采用优化后的 RBM 的学习率,应用提出的 DBN 方法提取特征,第 2 个 RBM 提取的特征即为 DBN 最终提取的特征。

第 1 个 RBM 和 DBN 最终提取的特征维度分别是 50 和 25,为了展示特征分布状况,在此应用核主成分分析(kernel principal component analysis, KPCA)方法获取第 1 个 RBM 和 DBN 最终提取的特征的 3 个主成分,并将其于 3 维图中显示。图 3 所示为第 1 个 RBM 提取的特征分布状况,F0 和 F2,F1 和 F14,F3,F7 和 F11 早期故障类别之间有明显的重叠。图 4 展示了 DBN 最终提取的特征分布状况,仅 F0 和 F2,F7 和 F11 早期故障类别之间存在轻微的重叠,其他各个早期故障类别均被 DBN 方法明确地分开,图 3 和 4 所示为基于 DBN 方法提取特征的过程,即输入数据在经历了两个 RBM 的非线性映射的重构数据后,对输入数据的抽象表示进一步精确,特征重叠的数据数量减少,且各个相同的早期故障类别分布区域变得更加紧密。

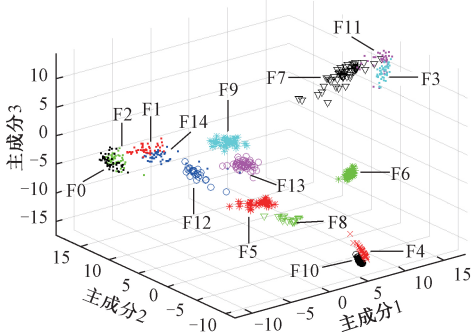


图3 第1个 RBM 提取的特征的主成分分布
Fig.3 The principal component distribution of the features extracted using the first RBM

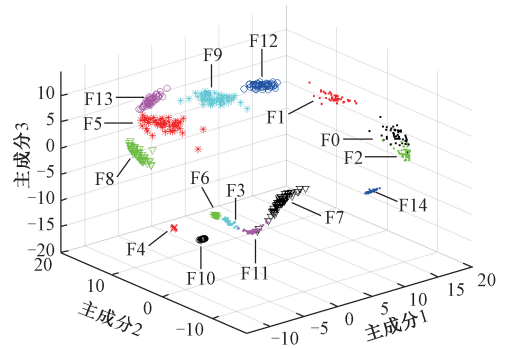


图4 DBN 提取的特征的主成分分布
Fig.4 The principal component distribution of the features extracted using the DBN

为了对比本文提出的基于 DBN 的模拟电路早期故障特征提取方法的特征提取效果,将其与小波变换方法进行对比实验。基于提取的二级四运放双二阶低通滤波器响应信号作为原始数据,采用 Haar 小波对测量数据分解至第 5 层^[3],提取的小波特征经 KPCA 提取 3 个主成分,分布如图 5 所示,F0、F1、F2、F9 和 F13,F5 和 F8,以及 F7 和 F11 早期故障类别之间均存在重叠。将图 4 和图 5 的特征分布进行对比,本文提出的 DBN 方法提取的特征相比于小波变换方法提取的特征,具有更少的重叠数据,不同的早期故障类别数据之间分离程度更高,相同的早期故障类别数据聚合得更加紧密,有益于提高后续分类方法的正确识别率。




图5 小波变换提取的特征的主成分分布
Fig.5 The principal component distribution of the features extracted using wavelet transform

对提取的特征数据应用 CPSO 算法,参考 3.2 节中的步骤,优化生成的惩罚因子和折衷参数分别为 82.695 7和 0.531 0,进而建立基于 GMKL-SVM 算法的早期故障诊断模型,诊断结果如表 2 所示,GMKL-SVM 诊断模型完全正确地诊断出 F1、F3、F4、F5、F6、F8、F9、F10、F12、F13 和 F14 故障,50 个 F0 故障正确识别了 45 个,其他 5 个识别为 F2 故障;50 个 F2 故障正确识别了 46 个,其他

4 个识别为 F0 故障;50 个 F7 故障正确识别了 47 个,其他 3 个识别为 F11 故障;50 个 F11 故障正确识别了 48 个,其他 2 个识别为 F7 故障。整体的早期故障诊断正确率为 98.13%。表 1 中各个元件的故障值均为早期故障,在利用蒙特卡罗采集各个早期故障元件的实验数据时,其他非故障元件的参数值在设定的标称值 5% 容差范围内变化,而本文提出的 DBN 特征提取方法和 GMKL-SVM 故障诊断模型均可以较为准确地识别各个早期故障,这说明了本文提出的 DBN 特征提取方法和 GMKL-SVM 故障诊断模型在非故障元件参数变化扰动时仍然具有较强的鲁棒性。进一步地,对本次实验的各项执行时间进行统计,结果如表 3 所示。由表中各项执行时间可以看出,在花费的训练时间中,DBN 的两个学习率的优化所花费的时间最长,其原因在于 DBN 中 RBM 的时间复杂度较大。在训练结束后,可将建立的 DBN 特征提取方法和 GMKL-SVM 故障诊断模型用于测试,测试时间分别为 (2.0 ± 0.1) s 和 (1.6 ± 0.1) s,符合故障诊断的测试要求。

表 2 低通滤波器的诊断结果

Table 2 The diagnosis results of the lowpass filter

早期故障码	早期故障类别	诊断结果/%
F0	NF	90
F1	R4 ↑	100
F2	R4 ↓	92
F3	R6 ↑	100
F4	R6 ↓	100
F5	R7 ↑	100
F6	R7 ↓	100
F7	R9 ↑	94
F8	R9 ↓	100
F9	R18 ↑	100
F10	R18 ↓	100
F11	C2 ↑	96
F12	C2 ↓	100
F13	C4 ↑	100
F14	C4 ↓	100

表 3 各类操作的执行时间

Table 3 The execution time of various operations (s)

训练过程		测试过程	
优化学习率	建立分类模型	特征提取	诊断
23.6±0.8	9.2±0.4	2.0±0.1	1.6±0.1

4.2 对比实验

以往 DBN 中学习率一般采用经验法设定,为了说明应用 CPSO 方法优化 DBN 中学习率的先进性,现进行对

比实验。分别采用经验法中常用的 0.01、0.02、0.03、0.05、0.1 和 0.2 作为 DBN 中 RBM 的学习率,用于提取本文中采集的二级四运放双二阶低通滤波器电路响应信号的特征,随后按照本文的方法划分训练数据和测试数据,并采用本文中的 GMKL-SVM 方法进行建模识别,表 4 所示为对比实验的结果,可以看出,在学习率为 0.01 和 0.02 时可以获得较高的诊断正确率,然而此时学习率仍未达到最优,本文在应用了 CPSO 方法优化学习率后,获得其最优值可生成更高的诊断正确率,即证明了应用 CPSO 方法优化学习率相比传统经验法的先进性。

表 4 不同学习率时诊断结果的对比

Table 4 Diagnosis result comparison for different learning rates

学习率	诊断结果/%
0.01	96.8
0.02	96.4
0.03	96.13
0.05	95.33
0.1	94.93
0.2	94.27

进一步地,为了验证本文提出的基于 DBN 的特征提取方法的性能,现将本文提出的提取方法与电路故障诊断中常用提取方法^[3, 6, 8]进行对比实验。文献[3]中应用小波变换方法提取小波量作为特征,文献[6]提取测量信号的峭度和熵作为特征,文献[8]中应用小波分形分析进行故障特征的提取。现将本文中采集的低通滤波器电路各早期故障类别的脉冲响应信号,分别应用小波变换方法、提取信号峭度和熵方法、小波分形分析方法提取故障特征,随后按照本文的方法划分训练数据和测试数据,并应用本文中 GMKL-SVM 方法进行建模识别。表 5 所示为对比实验的结果,结果表明,在常用的 3 种特征提取方法中,提取峭度和熵的方法可以获得最高的故障诊断正确率。而本文提出的基于 DBN 的特征提取方法在早期故障诊断中正正确率高于提取峭度和熵的方法,说明 DBN 方法可以有效地提取早期故障的本质和深度特征,更有效地表达了原始数据到特征之间的非线性映射,性能优于其他常见特征提取方法,有利于早期故障的精准识别。

表 5 各方法诊断结果的对比

Table 5 Diagnosis result comparison of various approaches

方法	诊断结果/%
小波变换	96.53
峭度和熵	97.07
小波分形分析	96.13
提出的 DBN 方法	98.13

4.3 实验验证

为了验证本文提出的方法可以应用于实际电路的早期故障诊断,在此通过 Sallen-Key 带通滤波器实际电路进行验证,如图 6 所示,实测中激励为 Tektronix AFG3152C 信号发生器产生的持续时间 $10\ \mu\text{s}$ 和幅值 $10\ \text{V}$ 的脉冲波,响应信号的采集应用 Keysight MSOX2024A 示波器。选择 R1、R2、R3、R4 和 R5 作为测试元件,其故障模式为元件参数值漂移标称值在 $5\% \sim 25\%$ 之间均匀分布,共设定 11 种故障模式,如表 6 所示。各个故障类别共采集 50 个数据,25 个作为训练数据,25 个作为测试数据。针对测试数据,DBN 中学习率优化得到的参数值为 0.097 497 555 735 180 和 0.031 213 082 257 186,提取的特征如图 7 所示。由图 7 可以看出,11 个故障类别均明显地独立分布,相互区分,这说明了本文提出的基于 DBN 特征提取方法不仅可用于仿真电路,亦可应用于实际电路。随后应用 GMKL-SVM 对该实际电路板进行早期故障建模和测试,得到的诊断正确率为 100% 。




图 6 Sallen-Key 带通滤波器电路实验方案

Fig.6 The experiment scheme of the Sallen-Key bandpass filter circuit

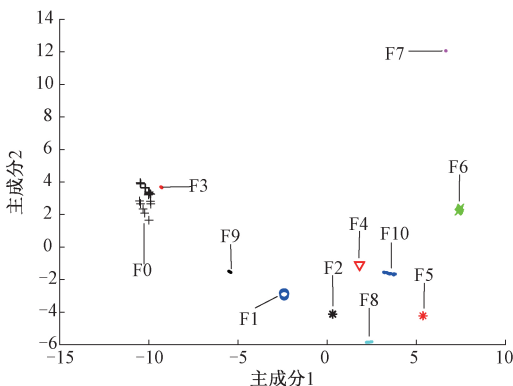


图 7 实测电路的特征的主成分分布

Fig.7 The principal component distribution of the features of the experiment circuit

表 6 实测电路中测试元件的各项参数

Table 6 The parameters of the test components in the experiment circuit

早期故障码	早期故障类别	标称值/ $\text{k}\Omega$	早期故障值/ $\text{k}\Omega$
F0	NF	-	-
F1	R1 \uparrow	1	1.05~1.25
F2	R1 \downarrow	1	0.95~0.75
F3	R2 \uparrow	3	3.15~3.75
F4	R2 \downarrow	3	2.85~2.25
F5	R3 \uparrow	2	2.1~2.5
F6	R3 \downarrow	2	1.9~1.5
F7	R4 \uparrow	4	4.2~5
F8	R4 \downarrow	4	3.8~3
F9	R5 \uparrow	4	4.2~5
F10	R5 \downarrow	4	3.8~3

5 结 论

本文提出了一种基于 DBN 特征提取的模拟电路早期故障诊断方法。首先采集被测电路的信号数据,随后应用 DBN 方法提取信号的深度和固有特征,对于影响 DBN 连接权重更新的参数-RBM 的学习率,应用 CPSO 方法优化生成。应用生成的特征,建立基于 GMKL-SVM 的早期故障诊断模型,其中惩罚因子和折衷参数应用 CPSO 算法优化。二级四运放双二阶低通滤波器仿真电路和 Sallen-Key 带通滤波器电路板展示了实验的过程,对比实验中表明,本文提出的基于 DBN 的特征提取方法,优于传统的特征提取方法,可进一步地提高故障诊断正确率。

参考文献

- [1] 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 SH, 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.
- [2] 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 & Measurement, 2007, 56(5):1546-1554.
- [3] ZHANG C, HE Y, YUAN L, 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.
- [4] CUI J, WANG Y. A novel approach of analog circuit fault diagnosis using support vector machines classifier [J]. *Measurement*, 2011, 44(1): 281-289.
- [5] GAN X SH, GUO W M, ZHE D, et al. Research on WNN soft fault diagnosis for analog circuit based on adaptive UKF algorithm [J]. *Applied Soft Computing*, 2017, 50(C):252-259.
- [6] ZHEN Z, DUAN Z, YING L, et al. A new swarm-SVM-based fault diagnosis approach for switched current circuit by using kurtosis and entropy as a preprocessor [J]. *Analog Integrated Circuits & Signal Processing*, 2014, 81(1):289-297.
- [7] XIAO Y, FENG L. 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.
- [8] 张朝龙, 何怡刚, 袁莉芬, 等. 基于 GMKL-SVM 的模拟电路故障诊断方法 [J]. *仪器仪表学报*, 2016, 37(9): 1989-1995.
- ZHANG CH L, HE Y G, YUAN L F, et al. Analog circuit fault diagnosis based on GMKL-SVM method [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(9): 1989-1995.
- [9] LONG B, XIAN W, LI M, et al. Improved diagnostics for the incipient faults in analog circuits using LSSVM based on PSO algorithm with Mahalanobis distance [J]. *Neurocomputing*, 2014, 133(10):237-248.
- [10] XU L, HUANG J, WANG H, et al. A novel method for the diagnosis of the incipient faults in analog circuits based on LDA and HMM [J]. *Circuits, Systems and Signal Processing*, 2010, 29(4): 577-600.
- [11] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [12] 赵光权, 葛强强, 刘小勇, 等. 基于 DBN 的故障特征提取及诊断方法研究 [J]. *仪器仪表学报*, 2016, 37(9):1946-1953.
- ZHAO G Q, GE Q Q, LIU X Y, et al. Fault feature extraction and diagnosis method based on deep belief network [J]. *Chinese Journal of Scientific Instrument*, 2016,37(9):1946-1953.
- [13] LEE H, GROSSE R, RANGANATH R, et al. Unsupervised learning of hierarchical representations with convolutional deep belief networks [J]. *Communications of the ACM*, 2011, 54(10):95-103.
- [14] CHEN Y SH, ZHAO X, JIA X P. Spectral-spatial classification of hyperspectral data based on deep belief network [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2015, 8(6): 2381-2392.
- [15] LIU ZH B, JIA ZH, 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.
- [16] CORTES C, VAPNIK V. Support-vector networks [J]. *Machine learning*, 1995, 20(3): 273-297.
- [17] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory [C]. *International Symposium on MICRO Machine and Human Science*, 2002:39-43.
- [18] CHEN F F, TANG B P, SONG T, et al. Multi-fault diagnosis study on roller bearing based on multi-kernel support vector machine with chaotic particle swarm optimization [J]. *Measurement*, 2014, 47(1): 576-590.
- [19] ZHOU Q, ZHANG W, CASH S, et al. Intelligent sizing of a series hybrid electric power-train system based on chaos-enhanced accelerated particle swarm optimization [J]. *Applied energy*, 2017, 189(3): 588-601.

作者简介



张朝龙, 2018 年于合肥工业大学获得博士学位, 现为武汉大学博士后、安庆师范大学副教授, 主要研究方向为故障诊断和预测。

E-mail: zhangcl@aqnu.edu.cn

Zhang Chaolong received his Ph. D. degree from Hefei University of Technology in 2018. He is currently a post doctoral researcher at Wuhan University and an associate professor at Anqing Normal University. His main research interests include fault diagnostics and prognostics.



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、博士生导师, 主要研究方向为电路理论及其应用、模拟和混合信号电路的测试和故障诊断、智能电网、射频识别技术和智能信号处理。

E-mail: 18655136887@163.com

He Yigang received his Ph. D. degree from Xi'an Jiaotong University in 1996. He is currently a professor and doctoral supervisor at Wuhan University. His main research interests include circuit theory and its applications, testing and fault diagnosis of analog and mixed-signal circuits, smart grid, radio frequency identification technology, and intelligent signal processing.