

DOI: 10.19650/j.cnki.cjsi.J2210218

基于对数分布参考点 LDRP 的分解多目标进化 MOEA/D 算法实现模拟电路故障参数估计*

杨成林, 张棋皓, 王浩
(电子科技大学 成都 611731)

摘要: 模拟电路随工作时间的增加, 其健康状态也在不断下降。及时对早期故障状态的元件进行参数估计, 可以准确地评估设备健康状态, 为故障预测提供参考。基于被测电路的传递函数和实测的故障响应, 可反推出可能的故障参数。由于容差的影响, 有很多参数组合可以产生相同的故障响应。本文通过数学分析, 将故障参数估计问题转化为多目标优化问题, 并针对优化目标量级相差巨大、难以合理生成权重向量进行环境选择等问题, 提出基于对数分布参考点来指导种群进化, 并提出了一种基于对数分布参考点的分解多目标进化算法, 该方法能够准确且稳定地找到故障参数估计问题的最优解, 通过仿真跳藕滤波电路, 验证了随容差的增大, 参数范围越来越宽, 且所有标准偏差最大仅 18.616Ω , 在时间效率上, 具有 3 种不同容差的 12 个故障实例的运行时间没有显著差异, 平均运行时间为 0.7 s , 和实际电路实验证明了该算法的正确性和鲁棒性, 并通过对比该方向前沿研究的其他多种算法, 验证了本文的方法在精度上优于双目标进化算法 2~3 个数量级, 对比 Tadeusiewicz 提出的方法具有更宽的故障区间等, 验证了本文的方法具备更高的准确性和有效性, 体现了本文方法的优越可靠。

关键词: 参数估计; 容差; 参考点; LDRP; 多目标优化

中图分类号: TN710 TH17 文献标识码: A 国家标准学科分类代码: 460.4

Fault parameter estimation of analog circuits using the decomposed multi-objective evolutionary algorithm MOEA/D based on logarithmic distribution reference points LDRP

Yang Chenglin, Zhang Qihao, Wang Hao

(University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: With the increase of working time, the health status of analog circuit declines. The faulty parameter estimation in early fault state can accurately evaluate equipment health state and provide reference for fault prediction. Based on the transfer function of the circuit and the measured fault response, the possible fault parameters can be inversely derived. Due to the influence of tolerance, the same fault response can be generated by many parameter combinations. This article transforms the fault parameter estimation problem into a multi-objective optimization problem through mathematical analysis. In view of the problems of the huge difference in the optimization objective scale and the difficulty in generating a reasonable weight vector, it proposes to guide the population evolution based on the logarithmic distribution reference point and proposes a logarithmic distribution reference point-based decomposition multi-objective evolution algorithm. This method can accurately and stably find the optimal solution of the fault parameter estimation problem. Through simulation of the jump filter circuit, it is verified that as the tolerance increases, the parameter range becomes wider, and the maximum standard deviation is only 18.616Ω . In terms of time efficiency, there is no significant difference in the running time of 12 fault instances with three different tolerances, and the average running time is 0.7 s . The correctness and robustness of the algorithm are verified by experiments, and compared with other multi-objective evolution algorithms in the forefront of this direction, the method proposed in this article is more accurate than the bi-objective evolution algorithm by 2~3 orders of magnitude in terms of accuracy, and has a wider fault interval than the method proposed by Tadeusiewicz, which verifies the higher accuracy and effectiveness of the method proposed in this article, reflecting the superiority and reliability of the method proposed in this article.

Keywords: parameter estimation; tolerance; LDRP; reference points; multi-objective optimization

收稿日期: 2022-07-29 Received Date: 2022-07-29

* 基金项目: 国家自然科学基金 (61871100)、中央高效基本业务费 (ZYGX2020J012) 项目资助

0 引言

随着集成电路的发展,电子系统的复杂性不断增加,对电子系统的可维护性、故障诊断和寿命预测的要求越来越迫切。模拟电路作为电子系统的重要组成部分,其故障是电子系统失效的主要原因之一^[1]。通常,模拟电路的故障诊断包括故障检测、定位和参数估计。目前绝大多数的故障诊断方法都集中在故障检测和定位上,而处理故障参数估计的很少。故障检测和定位的目的是在模拟电路发生硬故障(短路或开路)或者软故障(参数漂移)后识别出故障元件。但是,即使准确识别出发生故障的元件,由于故障已经真实发生,对电子系统产生影响肯定是无法避免的。

如果电路中某个组件发生了 $(0, \infty)$ 范围内的任何故障,通过实际测量的故障响应和被测电路(circuit under test, CUT)的传递函数,可以反向推导出可能的故障参数。但是由于元件存在容差特性^[2],可以产生相同故障响应的模拟参数组合很多。因此,理论上可能的故障参数应该在一个特殊的区间 $[pl, pu]$ 内变化,该区间最小值为 pl ,最大值为 pu 。

因此,得到可能的故障参数范围后,作为使用者可以根据该组件的特性来对其具体退化情况进行判断。如果乐观处理可以认为该组件参数处于中间值,然后对元件状态进行持续监测,为将来维修提供建议;谨慎处理可以认为已经漂移到两个极值点,如果超过故障值应该马上进行维修,以保证系统稳定可靠地运行。除此之外,可以通过持续对组件的状态和参数进行监测,能够预测CUT的剩余使用寿命。因此,在模拟电路工作过程中,及时对元件参数进行估计可以有效防止功能故障的发生。

故障参数估计是故障诊断领域中一项具有挑战性的工作。然而,只有很少的研究涉及该问题。Dai等^[3]最早涉足这项研究,提出了一种在时域中使用迭代法对模拟电路进行参数估计的方法。然而,为了估计给定参数集的值,必须执行多次迭代。这种方法耗时且仅适用于小规模电路。基于矩阵理论中的伍德伯里公式,Tadeusiewicz等^[4]推断出由于几个元件的参数扰动而导致的测试点电压偏差是这些元件两端电压的线性组合。该方法的缺点是它假定无故障元件的标称值,此外,该方法需要访问多个节点。在2018年,Tadeusiewicz等^[5]提出的一种基于超定方程拟合的迭代方法,但是只能估计出一些特定的参数偏移故障。随后他们又提出了一种检测故障元件并评估其参数的方法^[6]。该方法通过使用Levenberg Marquardt方法来最小化测量电压和参数化函数之间差异的平方和,解决了最小二乘问题。由于该方法是测试后仿真(simulation after test, SAT)方法,理论上可以覆盖整个 $(0, \infty)$ 范围内的所有连续参数偏移。

随着对模拟电路故障预测和健康管理的研 究需求,本团队注意到了故障参数估计这一问题。Yang^[7-8]系统地阐述了故障参数估计问题并且分析了研究该问题的实际意义。通过数学分析,使用传递函数将参数估计问题转化为优化问题,分别提出了一种改进的遗传算法^[7]和双目标进化算法^[8]用于解决该问题,使用这两种方法能够获得有效的解决方案,但精度和准确度还有待提高。

1 基本思路

由于元件的容差特性影响,不同的模拟参数组合能够产生相同的故障效应,从而我们可以将可能的故障参数设定在特定区间内变化,例如,使用一个放大器实例来解释这个问题。如图1所示,CUT的传递函数可表示为 $h = \dot{U}_o / \dot{U}_i = -R_f / R_1$ 。假设电阻标称值 $R_1 = R_f = 10 \text{ k}\Omega$,公差 $\alpha = 1\%$ 。如果此电路发生故障,以输入 \dot{U}_i 为参考相量,测得的故障响应为 $h = \dot{U}_f = \dot{U}_o = -2$ 。在不失一般的情况下,若故障源为 R_f ,则 R_f 的下界 $pl = -h \times [R_1 \times (1 - 1\%)] = 2 \times [10 \text{ k}\Omega \times 0.99] = 19.8 \text{ k}\Omega$,其上界 $pu = -\dot{U}_f \times [R_1 \times (1 + 1\%)] = 2 \times [10 \text{ k}\Omega \times 1.01] = 20.2 \text{ k}\Omega$ 。因此可以得出结论:

当前的元件参数值 R_f 可能是 $[19.8 \text{ k}\Omega, 20.2 \text{ k}\Omega]$ 区间内的任意值。更一般地来说,如果实测响应为 \dot{U}_f ,则 R_f 可以是 $[pl, pu] = [-\dot{U}_f \times R_1 \times (1 - \alpha), -h \times R_1 \times (1 + \alpha)]$ 区间内的任意值。这即是本文研究的模拟元件故障参数估计问题。

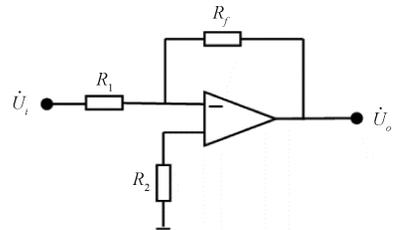


图1 反向放大器

Fig. 1 Inverting amplifier

一般来说,在线性模拟电路中,输入与输出的关系可以使用如式(1)的传递函数来表示。

$$h(\mathbf{p}) = \frac{\dot{U}_o}{\dot{U}_i} =$$

$$\frac{a_n(\mathbf{p})s^n + a_{n-1}(\mathbf{p})s^{n-1} + \cdots + a_1(\mathbf{p})s^1 + a_0(\mathbf{p})}{b_m(\mathbf{p})s^m + b_{m-1}(\mathbf{p})s^{m-1} + \cdots + b_1(\mathbf{p})s^1 + b_0(\mathbf{p})} \quad (1)$$

式中: $\mathbf{p} = [p_1, p_2, \cdots, p_K]$ 为元件参数向量(K 是电路元件的数量), $s = j\omega$, j 为复数单位, ω 为测试频率。如果元件

参数向量 \mathbf{p} 的第 f 个变量发生故障,那么元件 p_f 是当前的故障源,其中 $1 \leq f \leq K$ 。并且如果根据实际测量得到的故障响应是 \dot{U}_f ,本文的目标就是找到满足式(2)约束的最小和最大的 p_f 值。

$$E = \|h(\mathbf{p}) - \dot{U}_f\| = 0 \quad (2)$$

其中, E 表示通过仿真实验获得的响应 $h(\mathbf{p})$ 与实际测量的故障响应 \dot{U}_f 之间的差值。因此,故障参数估计问题可以转化为如式(3)的等式约束优化问题(equality constrained optimization problem, ECOP)。

$$\begin{cases} \text{minimize } f_1(\mathbf{p}) = \begin{cases} p_f, & \text{to obtain } pl \\ -p_f, & \text{to obtain } pu \end{cases} \\ \text{subject to } E = \|h(\mathbf{p}) - \dot{U}_f\| = 0 \\ p_i \in \begin{cases} (0, \infty), & i = f \\ [N_i \times (1 - \alpha_i), N_i \times (1 + \alpha_i)], & i \neq f \end{cases} \end{cases} \quad (3)$$

式中: N_i 是第 i 个元件的标称值, α_i 是第 i 个分量容差参数,一般取 $\pm 5\%$ 。假设第 i 个元件是无故障元件,那么其参数在容差范围内取值,也就是 $N_i \times [1 - \alpha_i, 1 + \alpha_i]$ 范围内。否则该元件为故障元件,在整个参数域 $(0, \infty)$ 内取值。 $f_1(\mathbf{p}) = p_f$ 和 $f_1(\mathbf{p}) = -p_f$ 分别用于求该 ECOP 的下限 pl 和上限 pu 。

通常情况下,等式约束很难得到满足。但是如果将故障元件参数 p_f 设置在可能的故障参数上下限 $[pl, pu]$ 的范围内,并且在容差范围内仔细调整其余无故障组件的参数值,则可以将误差 E 最小化到 10^{-4} 内,如图 2 中的 p_{f_2} 。但是,如果 p_f 设置在 $[pl, pu]$ 的范围之外,如图 2 中的 p_{f_1} 。则不可能将 E 最小化到足够小,因为无故障元件的容差通常非常小,它们无法抵消过大的故障量级造成的响应差值。在元件故障参数估计问题中,目标是找到满足等式约束 ($\|h(\mathbf{p}) - \dot{U}_f\| = 0$) 的最优解,更确切的说满足等式约束的两个极值点 pl 和 pu 。众所周知,处理等式约束的经典方式是采用放宽约束条件的优化技术,即通过预先定义一个正的容差值 δ 将式(3)的等式约束问题转换为式(4)的不等式约束问题。

$$\begin{cases} \text{minimize } f_1(\mathbf{p}) = \begin{cases} p_f, & \text{to obtain } pl \\ -p_f, & \text{to obtain } pu \end{cases} \\ \text{subject to } |h(\mathbf{p}) - \dot{U}_f| < \delta \\ \mathbf{p} \in \begin{cases} [N_i \times (1 - \alpha_i), (1 + \alpha_i)], & i \neq f \\ (0, \infty), & i = f \end{cases} \end{cases} \quad (4)$$

式(4)中符号定义和式(3)中相同。这种方法虽然暂时增加了可行空间,但是可行或高质量的候选解仍然难以通过种群进化得到^[9]。而且,使用容差值 δ 来放宽约束的方法存在固有的缺点,大的 δ 会降低精度,而小的

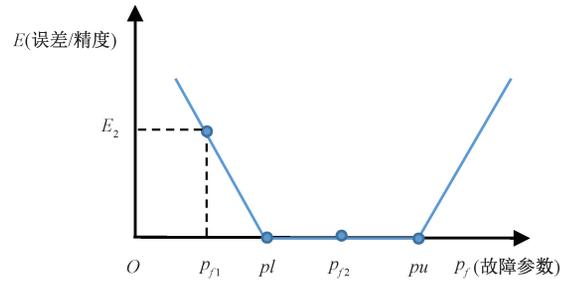


图2 故障参数范围

Fig. 2 Fault parameter range

δ 可能会导致种群陷入局部最优。典型的 δ 使用值是 10^{-4} ,它并不适用于所有实际应用。更麻烦的是,对于具有大量局部最优解的问题,很难选择合适的 δ 来引导种群进化。

由于故障参数估计问题的目标是找到图 2 中的两个极值点 pl 和 pu ,简单的放宽约束增加可行域也面临着无法高效的寻找最优解的问题。结合文献[8]中提出的基于帕累托(Pareto)支配的改进双目标遗传算法的思路。可以通过将单目标问题中式(2)的约束方程转化为一个最小化优化目标,构造出如式(5)所示的双目标优化问题。

$$\begin{cases} \text{minimize } F(\mathbf{p}) = (f_1(\mathbf{p}), f_2(\mathbf{p})) \\ f_1(\mathbf{p}) = \begin{cases} p_f, & \text{to obtain } pl \\ -p_f, & \text{to obtain } pu \end{cases} \\ f_2(\mathbf{p}) = \max\{0, |h(\mathbf{p}) - \dot{U}_f| - \delta\} \\ \text{subject to } \mathbf{p} \in \begin{cases} [N_i \times (1 - \alpha_i), (1 + \alpha_i)], & i \neq f \\ (0, \infty), & i = f \end{cases} \end{cases} \quad (5)$$

其中,如果第 f 个分量 p_f 是故障源,则它在 $(0, \infty)$ 的范围内变化;其余无故障组件 $p_i (i \neq f)$ 在其容差范围内变化。假设实际测得的故障响应为 \dot{U}_f ,被测电路的输入为 $\dot{U}_i = 1 \angle 0^\circ \text{ V}$ 。故障参数估计即是寻找满足方程 $h(\mathbf{p}) = \dot{U}_f$ 的解向量 \mathbf{p} ,其中第 f 个分量 p_f 的最小值和最大值。

式(5)的双目标优化问题 $F(\mathbf{p})$ 的 Pareto 前沿(Pareto front, PF)如图 3 所示。PF 和可行域的交点是故障参数区间 $[pl, pu]$ 的端点,图中标记了最小值 pl 和最大值 pu 。正如文献[10]的分析,故障参数估计问题的目标函数 $F(\mathbf{p})$ 的解与一般优化问题的最优解不同。一般优化问题的目标是获得一组解决方案(Pareto 最优解集)且解需要尽可能广泛且均匀地分布在 PF 上。但是,该问题的目标是在可行区域中找到两个最优解。 pl 要尽可能小,沿图 3 中的 PF 找到; pu 要尽可能大,沿图 3 中的虚线找到。所以该问题的最优解和一般优化问题有很

大区别。在求解时无需保证均匀分布 Pareto 最优解。通常,为了确保解均匀分布,基于参考点的技术被普遍使用于多目标进化算法(multi-objective evolutionary algorithm, MOEA)中,如 NSGA-III^[11]和 MOEA/D^[12]。因此,本文只需要实现随着种群进化不断逼近问题的真实 PF,解无需均匀分布在 PF 上。最终,通过 PF 和可行域的交点即可找到两个最优解。

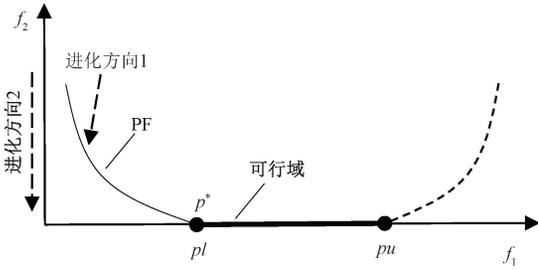


图3 $F(\mathbf{p})$ 的最优解示意图

Fig. 3 Schematic diagram of the optimal solution of $F(\mathbf{p})$

2 对数分布参考点

参考点的设置方法一直是 MOEAs 中的研究热点,因为参考点的设置方式影响着种群进化演变和 Pareto 最优解的分布。通常,为加速种群进化决策,算法会尝试将解尽可能靠近真实 PF,也就是获得良好的收敛性;同时,也需要让这些解尽可能广泛均匀地分布在 PF 上,即具有良好的多样性。参考点的分布情况和 MOEAs 在目标空间中如何探索新区域和开发当前区域息息相关。在 MOEA/D 中,参考点是为了生成权重向量来分解 MOPs,并且根据生成的权重向量可以高效地引导种群进化。但是在处理本文的研究问题中,参考点的作用不同。如式(2)所示,元件故障参数估计问题本质上是一个 ECOP。而目前解决 ECOPs 的方法大多数是使用一个较小的容差值将等式约束转为不等式约束。但是对于容差值的正确选取十分难点,且效果一般。

因此,为了种群能够在优化算法的引导下高效准确的进化收敛,需要调整生成参考点的策略。也就是说,参考点的生成策略应该更关注低值区域(可行域),且基于参考向量的优选方法需要同时从图3中的两条虚线所指的两个进化方向来指导种群进化和收敛。经过数学分析发现可以使用基于对数分布参考点(logarithmic distribution reference point, LDRP)来处理该问题。在图4(b)中, f_2 在半对数坐标中均匀分布。其中有7个点 f_2 的小于等于 ECOPs 的典型阈值 10^{-4} 。显然,它们比图4(a)中实数均匀分布的参考点更加关注可行域。并

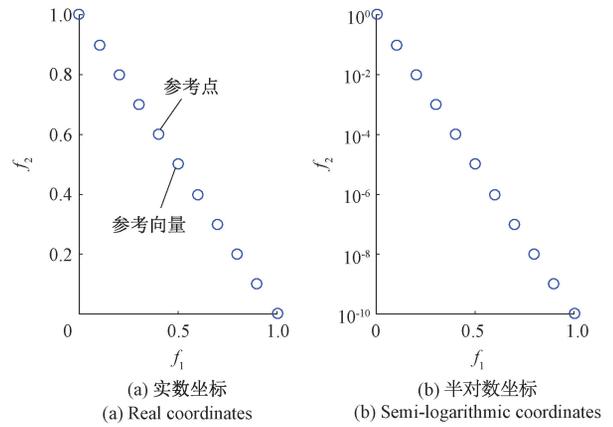


图4 参考点分布情况

Fig. 4 Distribution of reference points

且随着种群进化中最优解的更新,参考点也协同进化,后续关注可行域的权重向量也会越来越多。

参考点计算方法如式(6)所示。

$$\mathbf{W} = \begin{bmatrix} \mathbf{w}^{(1)} \\ \mathbf{w}^{(2)} \\ \mathbf{w}^{(3)} \\ \vdots \\ \mathbf{w}^{(n)} \end{bmatrix} = \begin{bmatrix} 1 - 10^{-1}, & 10^{-1} \\ 1 - 10^{\frac{-\delta^* - 1}{n-1} \times 1 - 1}, & 10^{\frac{-\delta^* - 1}{n-1} \times 1 - 1} \\ 1 - 10^{\frac{-\delta^* - 1}{n-1} \times 2 - 1}, & 10^{\frac{-\delta^* - 1}{n-1} \times 2 - 1} \\ \vdots & \vdots \\ 1 - 10^{-\delta^*}, & 10^{-\delta^*} \end{bmatrix} \quad (6)$$

式中: n 为参考点数目; δ^* 是当前进化种群的精度阈值。因此,按照式(6)生成的参考点均匀分布在半对数坐标中,如图4(b)所示。使用 LDRP 生成参考点在处理等式约束时不需要使用固定的容差值,并且该方法生成的权重向量能更加准确的引导种群沿着权重向量的方向收敛到理想点。

3 MOEA/D-LDRP 实现故障参数估计

解决等式约束问题的障碍来自在巨大的搜索空间中,定位高质量可行解的挑战。因此高效的进化算法应该实现以下两点:1)种群中满足要求的个体足够多,才能有效地生成下一代种群;2)能够引导种群进化的个体在算法的环境选择策略中能被准确优选到。通过数学推导,本文将 LDRP 和 MOEA/D 结合,提出了基于对数分布参考点的分解多目标进化算法(MOEA/D-LDRP)。MOEA/D-LDRP 的基本流程如图5所示,算法框架伪码如算法1所示。

1)首先测量 CUT 的故障响应 \hat{U}_f ,然后利用传递函数 $h(\mathbf{p})$ 和 \hat{U}_f ,通过故障定位方法^[13]找到故障源 p_f 。接下来,通过有限地随机产生 N 个个体并形成初始种群 P ,同时初始化算法基本参数。如果第 f 个分量是故障源,

算法 1: MOEA/D-LDRP 框架

输入: 传递函数 h , 故障响应 \dot{U}_f , 归一化参数 b

输出: 最优解 p

```

1:  $[P, \delta^*] = \text{Initialization}()$  // 初始化
2: For  $g = 1$  to  $G_{\max}$ 
3:    $P' = \text{Crossover\_Mutation}(P)$  // 交叉和变异
4:    $S = P \cup P'$  // 合并种群
5:    $W = \text{UpdateW}(n, \delta^*)$  // 按式(6)更新权重向量
6:    $\bar{F} = \text{Normalization}(S, b)$  // 按式(7)归一化
7:    $P = \text{Selection}(S, \bar{F}, W)$  // 按式(8)计算适应度并选择
8: End
9:  $i = \arg(\min_j f_2^{(j)})$ ,  $p^* = f_1^{(i)}$ ;
10: Return  $p^*$ 

```

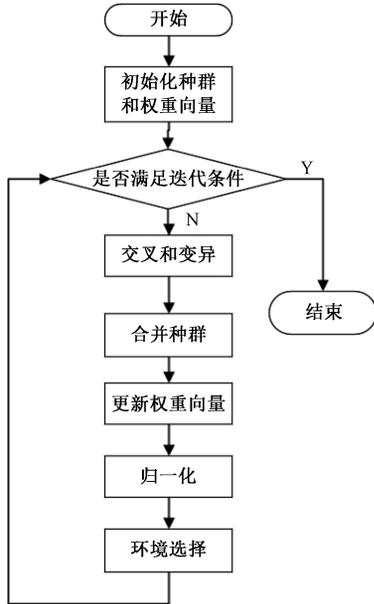


图5 故障参数估计流程图

Fig. 5 Flowchart of fault parameter estimation

则参数在内变化 $(0, \infty)$, 其他无故障元件在容差范围 $N_i \times [(1 - \alpha_i), (1 + \alpha_i)]$ 内变化。

2) 进行种群迭代。使用模拟二进制交叉和多项式变异操作^[14]生成下一代种群, 合并种群后按式(7)进行归一化操作。

由于研究问题的两个优化目标之间量级相差巨大, 需要使用准确的归一化方法。因为归一化对适应度计算和环境选择至关重要。归一化方法如式(7)所示。使用 \bar{f}_{pl} 归一化用于求解 pl 时且此时归一化参数 $b = 1$, \bar{f}_{pu} 用于求解 pu , 此时归一化参数 $b = -1$ 。

$$\begin{cases} \bar{f}_{pl} = \frac{f_1}{pl} \\ \bar{f}_{pu} = 2 - \frac{f_1}{pu} \end{cases} \quad (7)$$

3) 环境选择。在 MOEA/D 中通过聚合函数计算适应度(距离), 并执行环境优选操作。在环境选择中, 先将个体和权重向量关联, 然后选择每条权重向量所关联的距离最小的个体, 最后循环遍历关联信息直至选到种群数量个数的个体。距离可以通过 MOEA/D 的聚合函数 TCH 或 PBI 方法进行计算, 数学表达式如式(8)和(9)所示。

$$g^{TCH}(\bar{F}^{(i)} | w^{(j)}) = \max\left\{\frac{f_1(\mathbf{p}^{(i)})}{w_1^{(j)}}, \frac{f_2(\mathbf{p}^{(i)})}{w_2^{(j)}}\right\} \quad (8)$$

$$\begin{cases} g^{PBI}(\bar{F}^{(i)} | \mathbf{w}^{(j)}) = d_1 + \theta d_2 \\ d_1 = \frac{\|\bar{F}^{(i)} \mathbf{w}^{(j)}\|}{\|\mathbf{w}^{(j)}\|} \\ d_2 = \left\| \bar{F}^{(i)} - d_1 \frac{\mathbf{w}^{(j)}}{\|\mathbf{w}^{(j)}\|} \right\| \end{cases} \quad (9)$$

对于本文算法的时间复杂度, 交叉和突变操作(算法1中的第3行)的时间复杂度为 $O(nm)$, 更新 δ^* 需要 $O(n)$ 的时间复杂度。计算参考向量和归一化的时间复杂度为 $O(n)$ 。优选的时间复杂度为 $O(n^2)$, 将个体和权重向量关联的时间复杂度也是 $O(n^2)$ 。选择每条权重向量所关联的距离最小的个体时间复杂度为 $O(n \log_2 n)$ 计算。最终优选的时间复杂度为 $O(n)$, 因此, 整个算法的复杂度为 $O(n^2)$ 。

4 实例验证

为了能够检验提出算法的性能及普适性, 使用跳藕滤波电路进行验证, 电路如图6所示。元件的标称值列在图中, 直流电源为 ± 12 V, 激励(输入)信号是频率 1 kHz 的电压 1 V 正弦波。本文的算法在具有 2.0 GHz Inter 处理器和 32 G RAM 的 WINDOWS 操作系统上运行仿真。

如算法1所示, 求解下界 pl 归一化方法参数 $b = 1$, 求解上界 $b = -1$ 。算法中种群大小、交叉和突变率、最大代数和初始精度参数分别为 $N = 200$, $p_c = 1$, $p_m = 1/k$, $G_{\max} = 400$ 和 $\delta^* = -1.1$ 。其中, 初始化精度只是本实验选择的参数, 更加准确的取值需要进行实验分析, 该研究不在本文的探讨范围。

本实验在不同容差假设下检查具有不同故障参数的模拟元件。同时, 为了公平性每个实例运行 10 次。考虑到篇幅因素, 仅列出了 R_2, R_3, R_8 和 C_2 这 4 个具有代表性的组件。平均故障参数估计结果(每一栏的第1行)及其标准偏差(每一栏的第2行)列于表1中。

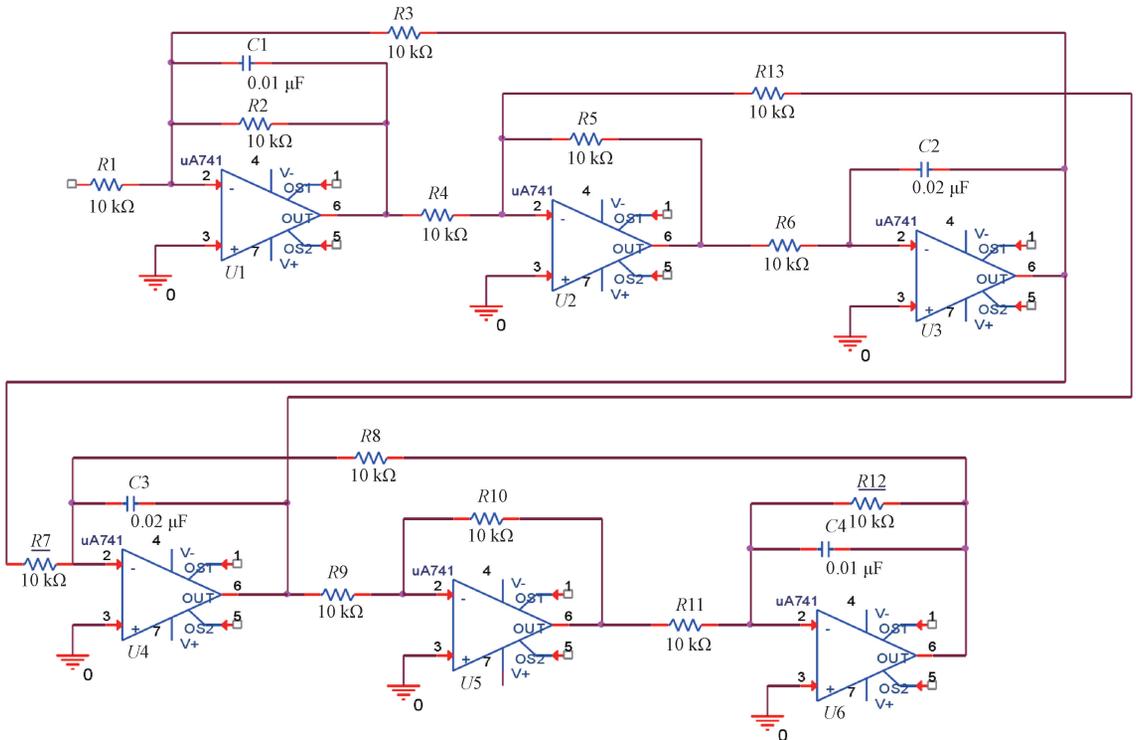


图6 跳藕滤波电路

Fig. 6 Jump-coupled filter circuit

以 $R_3 = 12 \text{ k}\Omega$ 为例,当容差为 $\alpha = 0.5\%$,算法发现的可能故障区间为 $[pl = 11\ 398 \ \Omega, pu = 12\ 664 \ \Omega]$,结果显示在表1的第11~12行的第3~4列。随容差的增大,参数范围越来越宽。当容差分别增加到1%和2%时,对应的故障参数范围扩大至 $[pl = 10\ 849 \ \Omega, pu = 13\ 400 \ \Omega]$ 和 $[pl = 9\ 885 \ \Omega, pu = 15\ 128 \ \Omega]$ 。标准偏差并没有随故障参数的变化而显著增加,而且所有标准偏差最大仅 $18.616 \ \Omega$ 。与故障参数 $12 \text{ k}\Omega$ 相比,该偏差非常小。与此同时,相同的结果也可以从图7得到。值得注意的是,从图7(a)中可以看出精度在0.01以上的部分个体分布不均匀。这是因为种群数目200,迭代次数400对于图6中具有17个元件(决策变量)的CUT来说太少了。一般来说,随决策变量的增加,人口规模和迭代次数应相应增加,该研究可以在遗传算法领域找到^[15]。综上,实验结果表明 MOEA/D-LDRP 在解决元件参数估计问题时具有良好的稳定性和健壮性。

在时间效率上,由于总体大小和最大生成数相同,因此具有3种不同容差的12个故障实例的运行时间没有显著差异。平均运行时间为0.7 s,具有优秀的时间运行效率。

为了进一步验证 MOEA/D-LDRP 的有效性,搭建如图8的实际CUT来检验。CUT的结构和参数与图6相同,元件容差为 $\pm 1\%$ 。直流电源为 $\pm 12 \text{ V}$,激励信号

是频率为 1 kHz 的电压 1 V 正弦波。响应值被采样并保存在精度为 2% ,量程为 $500 \text{ mV} \sim 10 \text{ V}$ 数字存储示波器中。

表2中列出了 R_2 和 R_3 两个代表性元件的故障参数估计结果。结果与表1中的数据略有不同,主要原因有3个。1) 在实际电路中的无故障元件和仿真实验中,具有不同的容差,它会产生不同的故障响应值 U_f 。2) 使用测量仪器会存在测量误差,也会影响测得的 U_f 。3) 即使获得了相同 U_f ,随决策变量增加,种群规模和代数太小也会导致结果不同。

5 对比试验

文献[3]的研究和文献[4]提出的模拟电路中多故障诊断的算法方法都可以实现故障参数估计,因此本文优先选择它们作为比较方法,此处分别称为“算法1”和“算法2”。

根据作者 Dai 在文献[3]中的建议,使用包含许多频率分量的标准阶跃波形,并使用与图6相同的测试点。结果如表3所示,此方法给出了唯一的参数估计,但如前所述,有限测量的解决方案应该是无穷大的,因此算法1相比于本文的方法,很难表现出其实用性。

表 1 故障参数估计的均值和标准差

Table 1 Mean and standard deviation of estimated fault parameters

故障源	故障参数	$\alpha=0.5\%$		$\alpha=1\%$		$\alpha=2\%$	
R_2	8 k Ω	7 627	8 398	7 279	8 827	6 653	9 806
		0.304	2.131	0.176	3.87	12.172	0.655
	12 k Ω	11 318	12 770	10 707	13 653	9 628	15 890
		1.614	1.532	0.77	1.218	5.367	5.447
	15 k Ω	14 004	16 161	13 140	17 539	11 686	21 188
		0.956	2.321	2.686	1.803	1.937	1.702
R_3	8 k Ω	7 673	8 350	7 367	8 727	6 806	9 588
		1.792	0.95	2.623	1.494	4.906	6.204
	12 k Ω	11 398	12 664	10 849	13 400	9 885	15 128
		2.882	3.385	2.67	2.994	1.393	12.316
	15 k Ω	14 137	15 963	13 363	17 041	12 023	19 663
		0.839	2.651	4.127	6.549	1.394	9.681
R_8	8 k Ω	7 476	8 543	6 957	9 105	5 944	10 272
		10.279	1.3	0.125	0.636	3.305	0.665
	12 k Ω	11 382	12 624	10 765	13 256	9 527	14 567
		6.868	1.357	19.343	11.649	6.171	8.212
	15 k Ω	14 316	15 702	13 653	16 423	12 317	17 927
		5.002	1.273	22.01	0.961	13.403	4.985
C_2	16 nF	15.4	16.62	14.82	17.264	13.711	18.616
	0.001	0.002	0.003	0.002	0.001	0.018	
24 nF	23.105	24.938	22.252	25.925	20.675	28.056	
	0.002	0.005	0.002	0.006	0.009	0.004	
30 nF	28.793	31.28	27.647	32.64	25.537	35.606	
	0.006	0.003	0.004	0.002	0.005	0.02	

表 2 实际电路故障参数估计结果

Table 2 Estimation results of actual circuit fault parameters

故障源	故障参数/k Ω	pI/Ω	pu/Ω
R_2	8	7 368	8 846
	15	13 283	17 549
	20	17 052	24 180
R_3	8	7 443	8 817
	15	13 545	16 926
	20	17 389	23 284

对于论文[4]中的算法 2,其结果通常比本文所提出的方法具有更窄的故障区间范围。例如,对于表 3 中, $R^2=8\text{ k}\Omega$ 的情况,本文方法实验得到的故障区间为

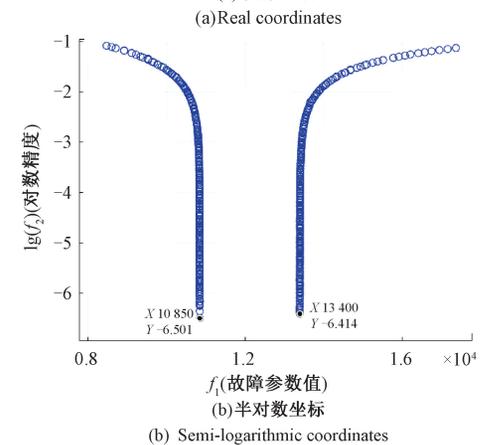
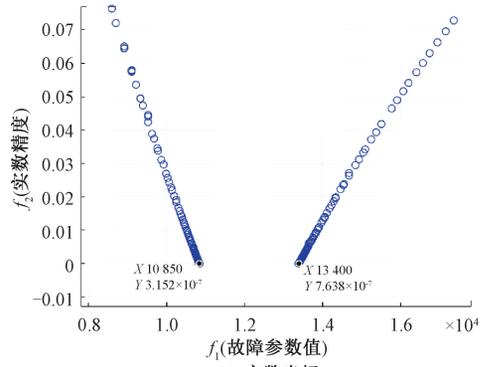


图 7 不同坐标下故障 $R_3=12\text{ k}\Omega$ 的参数估计结果
Fig. 7 Parameter estimation results of fault $R_3=12\text{ k}\Omega$ under different coordinates

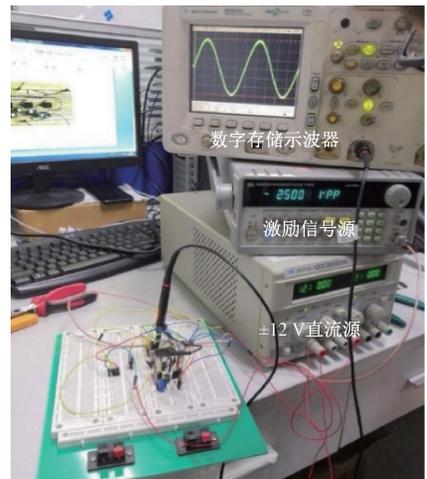


图 8 实际跳藕滤波电路
Fig. 8 Actual hop-coupling filter circuit

[7 301 Ω , 8 802 Ω], 而算法 2 得出的故障区间 [7 926 Ω , 8 366 Ω], 因此相比而言,本文的方法能够更彻底地确定故障区间范围。此外,算法 2 至少需要两个测试点(本例中使用第 2 个和第 3 个放大器的输出端

表3 电路故障参数估计结果对比(1)
Table 3 Comparison of circuit fault parameter estimation results (1)

故障源	故障参数/ Ω	MOEA/D-LDRP		算法 1	算法 2	
		pl	pu		pl	pu
R_2	5 k	4 616	5 397	4 653	4 703	5 340
	8 k	7 301	8 802	8 434	7 926	8 366
	12 k	10 792	13 724	11 358	11 943	12 983
	15 k	13 272	17 663	13 533	14 345	15 450
	20 k	17 192	24 548	20 453	18 478	22 768
R_3	5 k	4 738	5 463	4 987	4 790	5 321
	8 k	7 480	8 875	7 859	7 853	8 337
	12 k	10 999	13 606	12 673	11 459	12 499
	15 k	13 523	17 274	16 851	14 459	15 438
	20 k	17 528	23 390	22 687	18 542	21 798
R_4	5 k	4209	5 867	4 365	4 389	5 603
	8 k	6 932	8 990	7 459	7 983	8 125
	12 k	10 680	13 067	11 564	11 979	12 443
	15 k	13 564	16 191	14 256	14 368	15 524
	20 k	18 361	21 524	21 788	19 032	21 703

口)和许多测试频率($f=500$ Hz, 1 kHz 和 2 kHz),因此本文所提出的方法比文献[4]中作者 Tadeusiewicz 提出的方法更具有优势。

再对比前文提到的参考文献[7]中改进的遗传算法^[7](记作“算法3”)和参考文献[8]的双目标进化算法^[8](记作“算法4”),结果如表4所示。

以 $R_3=8$ k Ω 为例,用本文的方法发现的可能故障区间为 $[pl=7\ 367\ \Omega, pu=8\ 726\ \Omega]$,其标准偏差为 $[4.32\times 10^{-8}, 9.64\times 10^{-8}]$,而改进的遗传算法^[7]中的方法结果区间为 $[pl=7\ 351\ \Omega, pu=8\ 741\ \Omega]$,精度为 $[6.15\times 10^{-4}, 7.95\times 10^{-4}]$,该方法初始化较大的故障区间,然后通过连续划分和细化可能的故障区间来进行参数识别,因此,虽然从故障参数的区间范围来看似乎更好,但精度相差4个数量级,因为尽管可以通过增加迭代次数来提高精度,但其收敛性不足。因此,与文献[7]中的算法3相比,所提方法具有更高的精度和优势。

同样的例子下,对于双目标进化算法^[8],故障区间为 $[pl=7\ 384\ \Omega, pu=8\ 694\ \Omega]$,其标准偏差为 $[2.46\times 10^{-5}, 2.73\times 10^{-5}]$,其基于实数分布的参考线确实可以改善总体的分布和收敛性。但是,由于低值区域中的个体较少,

因此算法4无法有效提高准确性,与本文所提的方法相比,精度仍相差2~3个数量级,算法4稳定性明显劣于本文方法。

6 结 论

本文以故障诊断领域的故障参数估计问题为研究对象,使用改进的MOEA/D进行研究。首先分析了研究模拟元件故障参数估计问题的目的和作用。由于故障参数估计本质上是一个ECOP,其可行域小且放宽约束的处理方法选取容差值 δ 困难。因此,通过数学分析将其转化为多目标优化问题。然而,由于优化目标之间的量级相差巨大,如何合理生成权重向量并进行环境选择是一个难点。因此,推导出基于对数分布的参考点来指导种群进化。随后通过将LDRP与MOEA/D进行糅合,提出了基于对数分布参考点的分解多目标进化算法MOEA/D-LDRP。最后,通过仿真和实际电路实验证明了提出算法的正确性和鲁棒性。同时也为解决ECOPs提供了新思路,并且通过比较实验体现出了本文算法的优越性和可靠性。

表4 电路故障参数估计结果对比(2)
Table 4 Comparison of circuit fault parameter estimation results (2)

故障源	故障参数/ Ω	MOEA/D-LDRP		算法3		算法4	
		pl	pu	pl	pu	pl	pu
R_2	5 k	4 625 1.68×10^{-7}	5 423 1.12×10^{-7}	4 618 6.81×10^{-4}	5 437 6.74×10^{-4}	4 681 5.54×10^{-5}	5 386 1.09×10^{-4}
	8 k	7 284 1.14×10^{-7}	8 816 2.79×10^{-7}	7 276 6.07×10^{-4}	8 826 5.40×10^{-4}	7 333 3.91×10^{-5}	8 803 9.38×10^{-5}
	12 k	10 709 3.98×10^{-7}	13 646 1.82×10^{-7}	10 710 4.47×10^{-4}	13 673 6.29×10^{-4}	10 894 7.36×10^{-5}	13 571 7.12×10^{-5}
	15 k	13 143 5.37×10^{-7}	17 529 5.77×10^{-8}	13 179 5.08×10^{-4}	17 554 6.48×10^{-4}	13 239 1.12×10^{-4}	17 661 1.13×10^{-4}
	20 k	16 961 1.53×10^{-8}	24 416 9.41×10^{-8}	17 068 1.70×10^{-4}	24 447 4.38×10^{-4}	17 181 3.95×10^{-5}	24 460 1.81×10^{-5}
R_3	5 k	4 663 6.60×10^{-8}	5 373 4.97×10^{-8}	4 659 7.82×10^{-4}	5 386 7.38×10^{-4}	4 695 4.61×10^{-5}	5 348 3.22×10^{-5}
	8 k	7 367 9.64×10^{-8}	8 726 4.32×10^{-8}	7 351 6.15×10^{-4}	8 741 7.95×10^{-4}	7 384 2.73×10^{-5}	8 694 2.46×10^{-5}
	12 k	10 849 6.64×10^{-8}	13 395 3.35×10^{-8}	10 837 6.51×10^{-4}	13 398 6.35×10^{-4}	10 915 1.89×10^{-5}	13 312 4.36×10^{-5}
	15 k	13 365 3.95×10^{-8}	17 038 7.83×10^{-8}	13 614 6.39×10^{-4}	17 047 6.10×10^{-4}	13 573 3.35×10^{-5}	16 822 1.29×10^{-4}
	20 k	17 378 5.72×10^{-8}	23 386 1.09×10^{-7}	17 438 6.21×10^{-4}	23 410 7.78×10^{-4}	17 565 5.77×10^{-5}	23 026 6.47×10^{-5}
C_3	10	9.061 6.45×10^{-8}	10.98 5.07×10^{-8}	9.035 7.92×10^{-4}	11.01 6.67×10^{-4}	9.110 3.75×10^{-5}	10.886 $8.87E-06$
	16	14.82 1.04×10^{-7}	17.26 1.16×10^{-7}	14.81 7.10×10^{-4}	17.28 5.78×10^{-4}	14.91 5.16×10^{-5}	17.12 4.55×10^{-5}
	24	22.26 2.33×10^{-7}	25.91 2.39×10^{-7}	22.27 5.50×10^{-4}	25.91 6.29×10^{-4}	22.85 7.13×10^{-5}	25.20 2.32×10^{-4}
	30	27.67 2.57×10^{-7}	32.63 1.63×10^{-7}	27.68 5.62×10^{-4}	32.65 6.96×10^{-4}	29.26 3.93×10^{-5}	32.08 3.64×10^{-5}
	40	36.66 9.71×10^{-8}	43.66 7.67×10^{-8}	36.66 6.53×10^{-4}	43.68 6.93×10^{-4}	36.74 5.62×10^{-5}	43.38 6.89×10^{-5}

参考文献

- [1] 张朝龙. 模拟电路故障预测与健康管理的键技术研究[D]. 合肥:合肥工业大学, 2018.
ZHANG CH L. Research on key technologies of analog circuit fault prediction and health management [D]. Hefei:Hefei University of Technology, 2018.
- [2] 李水平. 模拟电路容差分析技术的应用与实现[D]. 成都:电子科技大学, 2012.

- LI SH P. Application and realization of analog circuit tolerance analysis technology [D]. Chengdu: University of Elect-ronic Science and Technology of China, 2012.
- [3] DAI H, SOUDERS T M. Time-domain testing strategies and fault diagnosis for analog systems [J]. IEEE Transactions on Instrumentation and Measurement, 1990, 39(1): 157-162.
- [4] TADEUSIEWICZ M, HAŁGAS S. An algorithm for

- multiple fault diagnosis in analogue circuits [J]. International Journal of Circuit Theory and Applications, 2006(34):607-615.
- [5] TADEUSIEWICZ M, HALGAS 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.
- [6] TADEUSIEWICZ M, HALGAS S. A method for multiple soft fault diagnosis of linear analog circuits [J]. Measurement, 2019, 131: 714-722.
- [7] YANG C. Genetic algorithm based faulty parameter identification for linear analog circuit[J]. IEEE Access, 2020, 8: 213357-213369.
- [8] YANG C. Analog circuit faulty parameter identification based on two-objective evolutionary algorithm[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [9] BARKAT ULLAH A S S M, SARKER R, LOKAN C. Handling equality constraints in evolutionary optimization[J]. European Journal of Operational Research, 2012, 221(3): 480-490.
- [10] WANG Y, CAI Z. Combining multiobjective optimization with differential evolution to solve constrained optimization problems [J]. IEEE Transactions on Evolutionary Computation, 2012, 16(1): 117-134.
- [11] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, Part I: Solving problems with box constraints [J]. IEEE Transactions on Evolutionary Computation, 2014, 18(4): 577-601.
- [12] ZHANG Q, LI H. MOEA/D: A multiobjective evolutionary algorithm based on decomposition[J]. IEEE Transactions on Evolutionary Computation, 2007, 11(6): 20.
- [13] YANG C, ZHEN L, HU C. Fault diagnosis of analog filter circuit based on genetic algorithm [J]. IEEE Access, 2019, 7: 54969-54980.
- [14] DEB K, AGRAWAL R B. Simulated binary crossover for

continuous search space[J]. Complex Syst, 1995(9): 115-148.

- [15] NAPOLI E, ZACHARELOS E, D'ARCO M, et al. Real-time downsampling in digital storage oscilloscopes with multichannel architectures [J]. IEEE Transactions on Circuits and Systems I-Regular Papers, 2021, 68(10).

作者简介



杨成林, 2011 年于电子科技大学获得博士学位, 现为电子科技大学副教授, 主要研究方向为模拟电路测试性设计, 故障诊断, 多目标优化智能算法。

E-mail: yangclin@uestc.edu.cn

Yang Chenglin received his Ph. D. degree from University of Electronic Science and Technology of China in 2011. He is currently an associate professor at University of Electronic Science and Technology of China. His main research interests include analog circuit test design, fault diagnosis, and multi-objective optimization intelligent algorithms.



张棋皓 (通信作者), 2021 年于江苏科技大学获得学士学位, 现就读于电子科技大学攻读硕士学位, 研究方向为大型集成电路和芯片的故障诊断。

E-mail: 693731052@qq.com

Zhang Qihao (Corresponding author) received his B. Sc. degree from Jiangsu University of Science and Technology in 2021. He is currently pursuing his master degree at University of Electronic Science and Technology. His research direction is fault diagnosis of large integrated circuits and chips.



王浩, 2020 年于河北工业大学获得学士学位, 现于电子科技大学攻读硕士学位, 现研究方向为故障诊断。

E-mail: 935570133@qq.com

Wang Hao received his B. Sc. degree from Hebei University of Technology in 2020. He is currently pursuing his master degree at University of Electronic Science and Technology. His current research direction is fault diagnosis.