

DOI:10.19651/j.cnki.emt.2105699

基于EMD复合多尺度熵的模拟电路故障诊断方法*

刘美容¹ 刘津涛^{1,2} 何怡刚³(1. 湖南师范大学 物理与电子科学学院 长沙 410081; 2. 湖南岳阳电视转播台 岳阳 414000;
3. 武汉大学 电气与自动化学院 武汉 430072)

摘要: 根据当今模拟电路高集成度、非线性以及易受环境影响等特点,提出一种基于经验模态分解(EMD)结合复合多尺度熵(CMSE)的故障特征提取新方法。首先通过仿真获得电路的输出信号,然后使用经验模态分解,将原始信号分解为有限个固有模态分量以及一个残余分量。再利用复合多尺度熵算法,分别计算出这些固有模态分量在不同时间尺度下的样本熵值,并据此构造能反映电路故障的特征向量。最后,构造BP神经网络,输入这些故障特征向量进行训练和测试,诊断出电路的故障类别。实验结果表明,该方法能将电路中表征故障的特征参数有效的提取出来,对电路的单故障识别有着较高的正确率。

关键词: 模拟电路;故障诊断;经验模态分解;复合多尺度熵;神经网络

中图分类号: TP206;TN707 **文献标识码:** A **国家标准学科分类代码:** 510.10

Simulation circuit fault diagnosis method based on EMD
composite multi-scale entropyLiu Meirong¹ Liu Jintao^{1,2} He Yigang³

(1. School of Physics and Electronics, Hunan Normal University, Changsha 410081, China; 2. Hunan Yueyang TV Station, Yueyang 414000, China; 3. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: A new fault feature extraction method based on empirical mode decomposition (EMD) and composite multi-scale entropy (CMSE) is proposed, according to the characteristics of analog circuits, such as high integration, nonlinearity and easy to be affected by environment. Firstly, the output signal of the circuit is obtained by simulation. Secondly, the limited intrinsic mode components and a residual component are obtained by empirical mode decomposition. Then, the composite multi-scale entropy algorithm is used to calculate the sample entropy values of these limited intrinsic mode components in different time scales, and the feature vectors which can reflect the circuit fault are constructed. Finally, these fault feature vectors are input into BP neural network for training and testing, and the fault categories of the circuit are diagnosed. The results show that the method can effectively extract the fault characteristic parameters in the circuit, and has a high accuracy in identifying different types of circuit faults.

Keywords: analog circuit; fault diagnosis; empirical mode decomposition; composite multi-scale entropy; neural network

0 引言

如今,高集成度和复杂度的模拟电路广泛的应用于各类智能仪器仪表中,信号的产生、放大、转换以及运算的可靠与否,与模拟电路息息相关。模拟电路若发生了故障,这些仪器仪表的正常运行将会受到影响。因此,在短时间内,准确地找到电路发生故障的原因,对于提高这些仪器设备的使用寿命与应用安全有着非常重要的意义^[1]。大量的实验研究表明,影响模拟电路故障诊断的关键因素主要是特

征提取与模式识别下两个方面。

特征提取是通过各种数据分析方法对原始数据进行处理,获得电路比较明显的故障特征,是故障诊断中的重中之重。小波变换、主成分分析、模糊理论、机器学习等方法已广泛应用于本领域之中^[2-7],其中小波变换更是获得众多研究者的一致认可,但是小波函数的选择以及冗余信息的处理也困扰着广大研究学者。经验模态分解(empirical mode decomposition, EMD)是一种自适应时频处理方法,它不需要设置任何基函数,仅依靠数据自身的时间尺度特征就可

收稿日期:2021-01-15

* 基金项目:国家重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200)、国家自然科学基金面上项目(51977153)资助

以对信号进行分解,因此特别适合处理非平稳和非线性信号。文献[8]将 EMD 分解与子带多态谱(subband polymorphic spectra, SPS)结合起来提取故障特征提取向量,该方法对于解决故障混叠难题,分离电路中的软故障和非线性故障,提升故障元件定位和分离能力表现比较突出。熵是一种评估系统内部有序化程度的指标,其中样本熵是通过度量信号产生新模式的概率大小来衡量信号的复杂程度,而多尺度熵就是在多个时间尺度下计算信号的样本熵。文献[9]将 EEMD(ensemble empirical mode decomposition)与多尺度熵结合起来提取故障特征向量,再利用 LSSVM 将模拟电路故障识别转化为特征分类阶段,该方法可以有效地提取模拟电路故障特征信息,能够实现模拟电路故障的精确诊断。

故障模式识别是模拟电路故障诊断中的另一个关键技术,一个高效的分类器对于诊断速度与精度的提升也是相当明显的,目前常见的分类方法有神经网络、支持向量机与极限学习机等^[10-12]。文献[10]结合了 LMD 与极限学习机对电路进行故障诊断,在诊断结果上表现较为优秀。BP 神经网络是目前应用最广泛的一种神经网络模型,它在处理非线性问题时有着良好的表现,而这也恰好应对了模拟电路的非线性特性。文献[11]运用布谷鸟搜索算法对广义回归神经网络进行网络参数优化,其诊断模型只需迭代较少次数就可获得很高的预测精度。

本文提出了一种基于 EMD 与复合多尺度熵的模拟电路故障特征提取的新方法。充分利用了 EMD 分解以及多尺度熵的特性,它们在处理模拟电路信号有其独到之处,再结合 BP 神经网络进行故障的分类识别,验证了本文设计方法的有效性。

1 经验模态分解

经验模态分解从本质上来说是一个把原始信号变得相对平稳的过程,它能将任何信号分解为若干个单一频率的 IMF 分量以及一个近似单调的 RES 残余分量,且不需要对原始信号做任何的预处理与分析,但是每一个 IMF 分量必须同时满足下面两个条件:

1)在整个时间范围内,信号序列的极值点个数与过零点个数相等,或者最多相差一个。

2)在信号的有限时间段内,由信号局部极大值形成的上包络线和局部极小值形成的下包络线所确定均值应该为 0。

EMD 分解可以将一个频率非常复杂的原始信号分解为多个单频率的分量信号。因此,EMD 很适合分析非平稳、非线性的信号序列。具体步骤如下:

1)首先对仿真电路设置适合的激励信号源,然后对测试节点信号采样得到输出响应信号 $f(t)$ 。

2)计算出响应信号 $f(t)$ 在有限区间内的极大值和极小值,然后采用 3 次样条插值法分别对极大值和极小值进

行拟合,得到信号的上包络线 $f_{\max}(t)$ 和下包络线 $f_{\min}(t)$,并求出上下包络线的均值为:

$$u(t) = (f_{\max}(t) + f_{\min}(t))/2 \quad (1)$$

3)计算原始信号 $f(t)$ 与均值信号 $u(t)$ 的差值,得到差值曲线 $p(t)$:

$$p(t) = f(t) - u(t) \quad (2)$$

4)对差值曲线 $p(t)$ 进行判定,如果能同时满足上述得到的两个约束 IMF 分量的条件,就可以将其视作第 1 个固有模态分量;如若 $p(t)$ 不满足条件,则将差值 $p(t)$ 作为新的初始信号 $f(t)$,重复步骤 1)~3),直到得出满足条件的 IMF 分量,记作 IMF_1 。

5)将剩余信号 $r(t) = f(t) - IMF_1$ 视为新的信号,并重复之前的步骤 1)~4),直到得到的 $r_n(t)$ 为常数或者是单调函数,则 EMD 分解结束。如此就将原始信号 $f(t)$ 分解为 n 个 IMF 分量和 1 个残余分量 $r_n(t)$ 。

$$f(t) = \sum_{i=1}^n IMF_i(t) + r_n(t) \quad (3)$$

2 复合多尺度熵

2.1 多尺度熵理论

多尺度熵是在样本熵的基础上,提出的一种用于评估时间序列复杂度的方法,表述了时间序列在粗粒化下的样本熵趋势。以样本熵为基础,反映了原始信号在不同尺度中的复杂程度和自相似性,因此可作为特征提取的指标^[13]。设原始数据长度为 $X = \{X_1, X_2, X_3, \dots, X_n\}$,具体计算步骤如下:

1)对 X 进行粗粒化处理,粗粒化过程主要是改变原始时间序列的尺度,构建新的粗粒向量,即:

$$y_i^\tau = \frac{1}{\tau} \sum_{i=(j-1)\tau}^{j\tau} x_i, 1 \leq j \leq \frac{N}{\tau} \quad (4)$$

式中: τ 为尺度因子; y_i^τ 是粗粒化向量。当 $\tau > 1$ 时,每段粗粒化时间序列的长度为 $\frac{N}{\tau}$ 。粗粒化的过程相当于用一个长度为 τ 的滑动窗,以不重叠的方式求取滑动窗内时间序列的平均值,图 1 是尺度因子 τ 分别取 2 和 3 时的粗粒化过程。




图 1 粗粒化过程

2)给定相似容限 r 和嵌入维度 m ,定义尺度 τ 下的粗粒化序列组成 m 维向量,即:

$$Y(i) = \{Y_i, Y_{i+1}, Y_{i+2}, \dots, Y_{i+m-1}\} \quad (5)$$

其中 $i = 1, 2, 3, \dots, n - m$ 。

3)定义 $Y(i)$ 与 $Y(j)$ 两个样本对应元素最大差值的绝对值为距离 $D(i,j)$,则:

$$D(i,j) = |Y(i) - Y(j)| = \max |X(i+k) - X(i-k)| \quad (6)$$

式中: $i,j=1,2,3,4,\dots,n-m;k=1,2,3,4,\dots,m-1$ 。

4)统计所有 $D(i,j) < r$ 的个数,并计算该数值与距离总数 $N-m-1$ 之间的比值,记为 $B_i^m(r)$:

$$B_i^m(r) = \frac{1}{N-m-1} \sum_{j=1}^{N-m-1} D(i,j) \quad (7)$$

其中, $1 \leq j \leq N-m, j \neq i$ 。当重构 m 维数据时,求样本的平均值相似度 $B^m(r)$:

$$B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r)$$

5)当重构数据为 $m+1$ 时,另重复执行步骤1)~4)计算出 $B^{m+1}(r)$ 。则原始序列的样本熵为:

$$SampleEntropy(m,r) = \lim_{N \rightarrow \infty} \left[-\ln \frac{B^m(r)}{B^{m+1}(r)} \right] \quad (8)$$

当 N 为有限数时,式(8)可表示为:

$$SampleEntropy(m,r,N) = -\ln \frac{B^m(r)}{B^{m+1}(r)} \quad (9)$$

6)则 MSE 可由样本熵与尺度因子 τ 表示为:

$$MSE(\tau | SampleEntropy(m,r,N)) = \left\{ \tau \left| -\ln \frac{B^m(r)}{B^{m+1}(r)} \right. \right\} \quad (10)$$

2.2 复合多尺度熵

在多尺度熵计算过程中,随着尺度因子增加而使得粗粒化序列长度降低,计算出来的样本熵有时会出现熵值不精确的问题,针对这一情况,提出一种复合多尺度熵的算法^[14-15]。

1)对于一个长度为 N 的原始序列 $X = \{X_1, X_2, X_3, \dots, X_n\}$,提前给定它的相似容限 r 与嵌入维数 m ,则可以构建粗粒化序列:

$$y_{k,i}^\tau = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau+k-1} x_i \quad (11)$$

其中, $1 \leq j \leq \frac{N}{\tau}, k=1,2,\dots,\tau; k$ 为在尺度 τ 下构造的滑动序列号。

相对于多尺度熵只生成一个粗粒序列,复合多尺度熵依次平滑移动生成 τ 个粗粒序列。图2是 $\tau=3$ 时的粗粒化过程。

2)计算每一次因滑动窗口而形成的粗粒化序列的样本熵,再对这些样本熵求均值,即可得到尺度因子为 τ 时的复合多尺度熵,则:

$$CMSE(\tau | m, r, n) = \frac{1}{\tau} \sum_{k=1}^{\tau} \left(-\ln \frac{B^m(r, k)}{B^{m+1}(r, k)} \right) \quad (12)$$

3 仿真实验及分析

3.1 故障诊断流程

本文运用EMD复合多尺度熵对仿真电路进行故障特




图2 $\tau=3$ 的复合多尺度熵粗粒化过程

征的提取,构造好故障特征向量后,将其输入BP神经网络中进行训练,最后输入测试集样本,完成故障模式的识别,具体的诊断流程如图3所示。

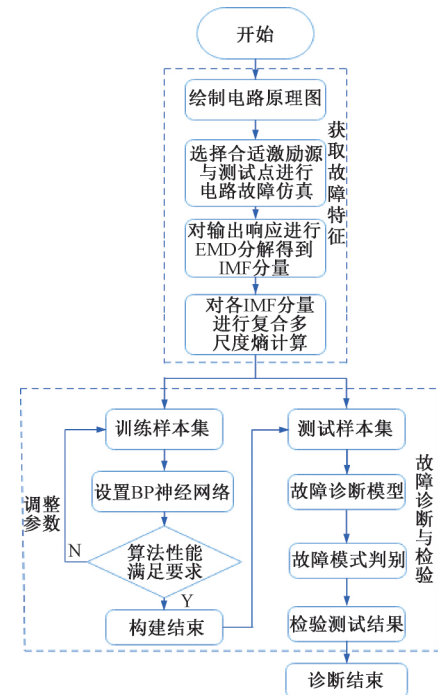


图3 故障诊断流程

具体的故障诊断步骤如下:

1)为待测电路选择合适激励信号,对电路进行灵敏度分析,找到对电路输出响应影响较大的元器件,将其设置为故障元件,通过改变它们的参数值设置不同的电路故障模式,选择故障节点,采集故障信息。

2)使用EMD分解处理采集到数据信息,得到若干个单一频率的IMF分量。

3)在多个时间尺度下计算每一个IMF分量的复合多尺度熵,并据此构造故障特征向量。

4)随机抽取部分样本作为训练数据,输入搭建好的BP神经网络进行训练。

5)将剩余样本作为测试数据输入训练好的BP神经网络进行故障诊断,检验故障的识别结果。

3.2 故障诊断实例

为验证本文方法的有效性,选用常见的sallen-key滤

波电路(如图 4 所示)进行仿真测试,依照上述故障诊断步骤进行实验。使用 PSPICE16.6 对电路进行仿真分析, MATLAB 2018b 进行数据处理。




图 4 sallen-key 带通滤波器

首先需要对仿真电路设置激励源,实验选取 3 个不同幅值和频率的正弦信号组成激励信号源。图 4 是 sallen-key 滤波电路所标识的元器件参数值即为电路的标称值,设电路中的电阻容差为 5%,电容容差为 10%,一般认为元器件的实际数值大于或小于标称值的 50%时,即可判定该元器件发生故障,在电路的输出端(图 4 中 OUT 处)采集输出信号。通过 PSPICE 灵敏度分析发现,R2、R3、C1、C2 容易对电路的输出响应产生较大的影响,故将其设置为故障元件,着重对其进行测试分析,且假设电路只会发生单故障,每个故障元件会发生参数正偏差和负偏差的故障,再加上正常状态,所以电路一共存在 9 种模式。具体故障设置如表 1 所示,NF 表示电路无故障。

表 1 电路故障模式

编号	故障类别	标称值	故障值	输出标签
F0	NF	—	—	100000000
F1	C1 ↑	5 nF	7.5 nF	010000000
F2	C1 ↓	5 nF	2.5 nF	001000000
F3	C2 ↑	5 nF	7.5 nF	000100000
F4	C2 ↓	5 nF	2.5 nF	000010000
F5	R2 ↑	3 kΩ	4.5 kΩ	000001000
F6	R2 ↓	3 kΩ	1.5 kΩ	000000100
F7	R3 ↑	2 kΩ	3 kΩ	000000010
F8	R3 ↓	2 kΩ	1 kΩ	000000001

对表 1 所示的 9 种故障模式分别进行 50 次 Monte Carlo 分析,一共会产生 450 个原始故障样本。对故障样本添加输出标签,编号 F0(即正常状态)的标签为 100000000,编号 F1(C1 大于标称值 50%)的标签为 010000000,其余依次类推。将得到的 450 个样本,随机选取 270 个进行训练,其余 180 个进行测试。

3.3 特征提取

对所有样本进行 EMD 分解,图 5 和 6 分别为部分正常状态下与 C1+50%状态下的分解结果。选择全部的 IMF

分量进行复合多尺度熵的计算不仅会降低神经网络的训练速度,也会因分量本身所含冗余信息而影响测试结果,且由于电路的大部分故障信息主要集中在前面的 IMF 分量中,因此本文选择前 3 个 IMF 分量来计算复合多尺度熵,对比图 5 和 6 可以看出,不同模式下的分解结果是有一定差异的。




图 5 正常状态下的 EMD 分解结果




图 6 C1+50%状态下的 EMD 分解结果

由于 IMF 分量本身就已经带有了一定程度的故障信息,所以本文同时将各 IMF 分量的能量特征作为另外一组故障特征向量,构建新的 BP 神经网络,与本文方法进行对比,部分数据如表 2 所示。

表 2 9 种模式下的 EMD 能量特征部分数据

编号	E(IMF1)	E(IMF2)	E(IMF3)
F0	9.393 5	25.492 5	8.435 6
F1	6.550 7	22.889 1	7.844 7
F2	15.314 9	27.725 9	6.715 9
F3	10.127 2	29.542 9	10.363 5
F4	8.566 9	16.195 0	3.418 6
F5	9.131 9	24.271 0	8.355 3
F6	10.238 7	29.423 3	5.911 9
F7	9.417 4	32.801 5	11.518 4
F8	7.634 4	13.986 3	3.326 6

复合多尺度熵的计算与选取的相似容量 r , 嵌入维度 m , 尺度因子 τ 有关, 本文选取 $m=2, r=0.2SD$ (原始数据标准差), τ 分别为 10、15、20, 因此最后计算得到的每一个样本中有 9 个特征参数, 部分数据如表 3 所示。

表 3 9 种模式下的 EMD 复合多尺度熵的部分数据

编号	IMF1 ₁₀	IMF1 ₁₅	IMF1 ₂₀	IMF2 ₁₀	IMF2 ₁₅	IMF2 ₂₀	IMF3 ₁₀	IMF3 ₁₅	IMF3 ₂₀
F0	0.031 0	0.361 7	0.448 7	0.018 4	0.033 8	0.042 7	0.064 6	0.218 3	0.075 0
F1	0.106 9	0.331 1	0.446 3	0.020 6	0.034 9	0.044 0	0.079 2	0.188 7	0.058 4
F2	0.033 0	0.303 4	0.414 5	0.191 0	0.240 8	0.041 9	0.075 9	0.085 2	0.062 6
F3	0.032 6	0.303 4	0.429 8	0.036 2	0.037 1	0.042 4	0.059 0	0.165 9	0.053 9
F4	0.034 9	0.336 5	0.455 2	0.153 7	0.087 5	0.044 3	0.060 4	0.112 4	0.056 7
F5	0.031 1	0.361 1	0.426 5	0.026 9	0.028 1	0.046 0	0.081 0	0.171 5	0.048 8
F6	0.042 6	0.354 6	0.440 6	0.133 7	0.066 3	0.045 0	0.119 0	0.153 9	0.064 3
F7	0.033 7	0.293 5	0.402 4	0.021 4	0.041 6	0.042 3	0.075 1	0.207 1	0.071 5
F8	0.038 0	0.327 3	0.439 1	0.194 3	0.239 7	0.041 1	0.071 1	0.072 1	0.058 9

3.4 结果分析

由 EMD 复合多尺度熵构建的 BP 神经网络的输入层节点数为 9 个, 与之对应的输出层节点数也是 9 个。经过不断测试, 发现当隐藏层的节点数设置为 14 时, 神经网络的训练效果较好。使用 BP 神经网络对已随机打乱的样本进行故障诊断。得到的测试结果如图 7 所示。作为对比实验的 EMD 能量特征测试结果如图 8 所示。




图 7 EMD 复合多尺度熵诊断结果

从图 7 所示的诊断结果可以得出, 测试所用的 180 个样本中有 1 个样本出现诊断错误, 实际本应为第 7 类的故障被误诊为第 3 类故障, 总体的诊断正确率为 99.44%; 由图 8 所示可知, 作为对比实验的 EMD 能量特征诊断结果中, 180 个测试样本中有 8 个出现诊断错误, 诊断正确率为 95.56%。由两者对比可知, EMD 能量特征与 EMD 复合多尺度熵都能对电路的故障进行较好的分类识别, 但是结合了 EMD 分解和复合多尺度熵的特征提取方法, 故障区分度更高, 诊断效果更好。

除了与设置的 EMD 能量特征法进行了对比实验之外, 也与其他文献的方法做了比较分析, 具体结果如表 4 所示。可以看出, 本文所提出的故障特征提取新方法, 诊断正确率要高于其他方法。




图 8 EMD 能量特征诊断结果

表 4 诊断正确率对比结果

方法	正确率/%
EMD 能量特征	95.56
文献[3]	96.67
文献[4]	97.78
EMD 复合多尺度熵	99.44

4 结 论

本文提出了一种经验模态分解结合复合多尺度熵的模拟电路故障诊断方法。通过 EMD 与复合多尺度熵构造故障特征向量, 再输入 BP 神经网络中进行故障模式识别的训练与测试。使用本文所提出的方法对 *sallen-key* 滤波电路进行故障诊断, 总体的正确率达到了 99.44%, 优于其他几种作为对比的故障诊断方法, 证实了本文研究方法的有效性。

参考文献

- [1] 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.
- [2] 袁莉芬, 孙业胜, 何怡刚, 等. 基于小波包优选的模拟电

- 路故障特征提取方法[J]. 电工技术学报, 2018, 33(1): 158-165.
- [3] 高坤, 何怡刚, 薄祥雷, 等. 共空间模式和超限学习机的模拟电路故障诊断[J]. 仪器仪表学报, 2015, 36(1): 126-133.
- [4] 董炜, 刘明明, 王良顺, 等. 基于群决策的道岔控制电路故障诊断方法[J]. 自动化学报, 2018, 44(6): 1005-1014.
- [5] 张朝龙, 何怡刚, 杜博伦. 基于 DBN 特征提取的模拟电路早期故障诊断方法[J]. 仪器仪表学报, 2019, 40(10): 112-119.
- [6] 胡含兵. 基于 MODWPT 与 LFDA 的模拟电路故障诊断[J]. 电子测量技术, 2019, 42(7): 49-53.
- [7] 夏爽, 颜学龙. 基于小波因子分析的 PSO-ELM 模拟电路故障诊断[J]. 国外电子测量技术, 2018, 37(9): 46-50.
- [8] 邓勇, 胡徐松. 基于 EMD 和 SPS 的容差模拟电路故障诊断[J]. 电子测量与仪器学报, 2020, 34(2): 67-72.
- [9] 庄城城, 易辉, 张杰. EEMD 多尺度熵和 LSSVM 在模拟电路故障诊断中的应用[J]. 微电子学与计算机, 2019, 36(10): 78-82.
- [10] 刘美容, 曾黎, 何怡刚, 等. 基于 LMD 多尺度熵和极限学习机的模拟电路故障诊断[J]. 电子测量与仪器学报, 2017, 31(4): 530-536.
- [11] 胡鸿志, 岑德炼, 徐翠锋, 等. 基于 CS 优化神经网络的模拟电路故障诊断[J]. 计算机工程与设计, 2019, 40(4): 1151-1155.
- [12] WANG D F, CHEN G W, XING D F, et al. Fault diagnosis method for switch control circuit based on SVM-AdaBoost[J]. Journal of Measurement Science and Instrumentation, 2020, 11(3): 251-257.
- [13] WU S D, WU C W, LIN S C, et al. Time series analysis using composite multiscale entropy [J]. Entropy, 2013, 15: 1069-1084.
- [14] NIU H L, WANG J. Quantifying complexity of financial short-term time series by composite multiscale entropy measure[J]. Commun Nonlinear Sci Numer Simulat, 2015, 22: 375-382.
- [15] 叶金义, 谢小平, 梁焯焯, 等. 基于精细复合多尺度熵特征向量相关系数在滚动轴承故障诊断中应用[J]. 噪声与振动控制, 2018, 38(5): 186-191.

作者简介

刘美容, 博士, 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

刘津涛, 硕士研究生, 主要研究方向为电路故障诊断。

E-mail: ljt1992819@163.com

何怡刚, 博导, 教授, 主要研究方向为极大规模集成电路设计测试与诊断、自动(射频)识别技术、信号处理等。

E-mail: 18655136887@163.com