

## 基于主元和判别集成分析的模拟电路故障诊断

肖迎群<sup>1</sup>, 何怡刚<sup>2</sup>, 刘继乾<sup>1</sup>, 张广辉<sup>1</sup>, 朱 珠<sup>1</sup>

(1. 贵州理工学院 电气工程学院, 贵阳 550003; 2. 合肥工业大学 电气与自动化工程学院, 合肥 230009)

**摘要:** 提出了主元和线性判别的集成分析算法以实施模拟故障数据的特征提取过程和方法. 该集成分析方法首先对模拟故障数据进行主元分析, 然后在主元变换空间实行线性判别分析, 最后将所获得的最优判别特征模式应用于模式分类器进行故障诊断. 仿真结果表明, 所提出的方法能够充分利用线性方法的计算简便优势, 增强单一主元分析或线性判别分析的特征提取性能, 获取故障数据集的本质特征, 简化模式分类器的结构, 降低系统运行的计算成本.

**关键词:** 模拟电路; 故障诊断; 特征提取; 主元分析; 线性判别分析

中图分类号: TP273

文献标志码: A

## Fault diagnosis of analog circuit by integrating principal component analysis with linear discriminant analysis

XIAO Ying-qun<sup>1</sup>, HE Yi-gang<sup>2</sup>, LIU Ji-qian<sup>1</sup>, ZHANG Guang-hui<sup>1</sup>, ZHU Zhu<sup>1</sup>

(1. School of Electrical Engineering, Guizhou Institute of Technology, Guiyang 550003, China; 2. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China. Correspondent: XIAO Ying-qun, E-mail: xiaoyingqun\_1210@sina.com)

**Abstract:** The method of feature extraction on analog fault data by integrating principal component analysis(PCA) and linear discriminant analysis(LDA) is proposed. Firstly, PCA on analog fault data is carried out. Then, LDA is implemented in the transformed PCA space for obtaining the optimal discriminant features. Finally, the acquired patterns are applied to the pattern classifier for fault diagnosis. The simulation results show that the proposed method can take advantage of the simple computation of linear methods, enhance the performance of feature extraction of single PCA or LDA method, acquire the intrinsic features in fault data set, simplify the structure of the pattern classifier and reduce the computational cost of the diagnostic system.

**Keywords:** analog circuit; fault diagnosis; feature extraction; principal component analysis; linear discriminant analysis

### 0 引 言

模拟电路故障诊断作为电路网络理论的一大分支已经得到了广泛的研究, 并取得了一系列有效的诊断技术和方法<sup>[1-2]</sup>. 然而, 随着现代电路复杂程度的增大, 精确高效的故障诊断变得愈加困难, 因此, 智能信息处理方法在电路故障诊断领域得到了大量的应用, 特别是电路信息的特征提取对故障诊断系统的性能提高起着非常重要的作用.

文献[3]将被测电路的故障响应信号不进行任何预处理作为神经网络的输入, 形成了一个具有38个输入节点和两个隐层的神经网络, 获得了95%的故障

诊断正确率. 文献[4-5]对被测电路的故障响应信号实施了小波变换和主元分析(PCA)的特征提取, 使得神经网络分类器的输入端子数大幅度减少, 单隐层神经元数降为10个左右, 故障诊断率提高到约97%.

文献[6-8]在使用PCA方法进行信号预处理的基础上, 分别提出了小波网络和脊波网络对模拟电路实施故障诊断. 这些新型网络提高了故障诊断的精确率, 但存在着网络结构庞大的问题, 即网络的输入节点数和隐层的小波或脊波元数比较多. 文献[9-10]分别使用非线性核主元分析方法和核判别分析方法来实施特征提取, 不仅提高了模拟故障诊断的正确率,

收稿日期: 2014-05-19; 修回日期: 2014-08-16.

基金项目: 贵州省自然科学基金项目(黔科合LH字[2014]7356号); 贵州理工学院高层次人才科研启动经费项目(XJGC20131203).

作者简介: 肖迎群(1975-), 男, 副教授, 博士后, 从事机器学习、故障诊断的研究; 何怡刚(1966-), 男, 教授, 博士生导师, 从事智能信息处理、故障诊断等研究.

而且降低了神经网络分类器的体系结构. 文献[11]在频域内对故障响应信号进行分析处理, 即分别计算故障响应信号的 Kurtosis 和 Entropy 值, 得到2个固定特征值作为神经网络的输入来进行故障诊断, 降低了网络的计算工作量, 获得了较好的分类效果.

尽管 PCA、线性判别分析(LDA)<sup>[12]</sup>和非线性核方法均能不同程度地简化神经网络分类器的结构, 并提高故障诊断系统的性能, 但是, 随着电子信息产业的急剧发展、模拟电路集成度的不断提高和故障元件表现行为的日趋复杂, 单一 PCA 或 LDA 方法存在着不能提取复杂故障信号的有效特征问题和非线性方法面临着运算成本高昂的困难. 因此, 为了提高模拟故障诊断的精确度, 增强线性方法的特征提取性能, 避免非线性特征提取方法的巨大计算量问题, 将两种 PCA 和 LDA 的线性方法进行集成融合, 构造主元和判别集成分析的特征提取方法, 实施模拟电路的故障特征提取研究, 分析集成方法的特征提取性能和模式分类器的故障诊断结果. 仿真结果表明, 所提出的方法能够充分利用线性方法的计算简便优势, 增强单一主元分析或线性判别分析的特征提取性能, 获取故障数据集的本质特征, 简化模式分类器的结构, 降低系统运行的计算成本.

## 1 主元和判别集成分析

### 1.1 理论基础

设有  $C$  个故障类别,  $S_b$ 、 $S_w$  和  $S_t$  分别表示类间分布矩阵、类内分布矩阵和总体分布矩阵,  $S_t = S_b + S_w$ , 线性判别准则函数定义为

$$J(X) = \frac{X^T S_b X}{X^T S_t X}. \quad (1)$$

假设  $\beta_1, \beta_2, \dots, \beta_n$  为  $S_t$  的  $n$  个正交归一化特征向量, 前  $m$  ( $m \leq n$ ) 个特征向量对应于前  $m$  正特征值. 定义子空间  $\phi_t = \text{span}\{\beta_1, \beta_2, \dots, \beta_m\}$ , 其正交补空间表示为  $\phi_t^\perp = \text{span}\{\beta_{m+1}, \beta_{m+2}, \dots, \beta_n\}$ , 则为  $S_t$  的零空间. 显然, 根据准则函数表达式(1), 可以从  $\phi_t$  中推导出所有最优判别向量. 由于  $\phi_t$  与  $m$  维欧氏空间  $R^m$  同构, 对应的同构映射为

$$X = PY, \quad P = (\beta_1, \beta_2, \dots, \beta_m). \quad (2)$$

其中:  $X \in \phi_t$ ,  $Y \in R^m$ . 将式(2)代入(1), 有

$$J(X) = \frac{Y^T (P^T S_b P) Y}{Y^T (P^T S_t P) Y} = \frac{Y^T \tilde{S}_b Y}{Y^T \tilde{S}_t Y} = \tilde{J}(Y). \quad (3)$$

其中:  $\tilde{S}_b = (P^T S_b P)$ ,  $\tilde{S}_t = (P^T S_t P)$ . 可见,  $\tilde{J}(Y)$  是与  $J(X)$  相同的判别准则.

设线性判别映射  $Z$  定义为

$$Z = W^T X, \quad (4)$$

其中  $W^T = (X_1, X_2, \dots, X_d)^T$ . 将式(2)代入  $W^T$ , 有

$$W^T = (PY_1, PY_2, \dots, PY_d)^T = (Y_1, Y_2, \dots, Y_d)^T P^T.$$

将式(4)分为如下两个部分:

$$Y = P^T X, \quad P = (\beta_1, \beta_2, \dots, \beta_m), \quad (5)$$

$$Z = V^T Y, \quad V = (Y_1, Y_2, \dots, Y_d). \quad (6)$$

由于  $P$  的列向量对应于  $S_t$  的非零特征向量, 式(5)的映射即为从  $R^m$  空间变换到  $R^m$  空间的 PCA, 函数  $\tilde{J}(Y)$  为 PCA 变换空间中的线性判别准则,  $Y_1, Y_2, \dots, Y_d$  为对应的线性最优判别向量.

### 1.2 主元和判别集成分析算法

根据上述理论分析, 得到主元和判别集成分析的基本算法如下.

**Step 1:** 在 PCA 变换空间  $R^m$  中, 计算类内分布矩阵  $\tilde{S}_w = P^T S_w P$  的正交归一化特征向量  $\gamma_1, \gamma_2, \dots, \gamma_m$ , 其中存在对应  $q$  个正特征值的  $q$  个特征向量.

**Step 2:** 令  $P_1 = (\gamma_{q+1}, \gamma_{q+2}, \dots, \gamma_m)$ ,  $\tilde{S}_b = P_1^T \tilde{S}_b P_1$ , 计算  $\tilde{S}_b$  的正交归一化特征向量  $Z_1, Z_2, \dots, Z_l$ , 则  $\tilde{\phi}_w = \text{span}\{\gamma_1, \dots, \gamma_q\}$ ,  $\tilde{\phi}_w^\perp = \text{span}\{\gamma_{q+1}, \dots, \gamma_m\}$ , 即正交补空间中的最优判别向量是  $Y_j = P_1 Z_j$  ( $j = 1, 2, \dots, l$ ). 通常,  $l = C - 1$ ,  $C$  为故障类别.

**Step 3:** 令  $P_2 = (\gamma_1, \gamma_2, \dots, \gamma_q)$ ,  $\tilde{S}_b = P_2^T \tilde{S}_b P_2$ , 计算  $\tilde{S}_b$  和  $\tilde{S}_t$  的  $d - l$  个广义特征向量  $Z_{l+1}, Z_{l+2}, \dots, Z_d$ , 这些特征向量对应于  $d - l$  个最大特征值, 因此,  $\tilde{\phi}_w$  中的最优判别向量为  $Y_j = P_2 Z_j$ ,  $j = l + 1, l + 2, \dots, d$ .

**Step 4:** 将  $Y_j = P_1 Z_j$  ( $j = 1, 2, \dots, l$ ) 与  $Y_j = P_2 Z_j$  ( $j = l + 1, l + 2, \dots, d$ ) 进行组合, 则  $\phi = (Y_1, Y_2, \dots, Y_l, Y_{l+1}, \dots, Y_d)$  即为最终的特征提取向量.

## 2 仿真分析

### 2.1 例子电路

以图1所示的四运放双二阶高通滤波器<sup>[5]</sup>为例来表明主元和判别集成分析进行模拟电路故障诊断的正确性和有效性.

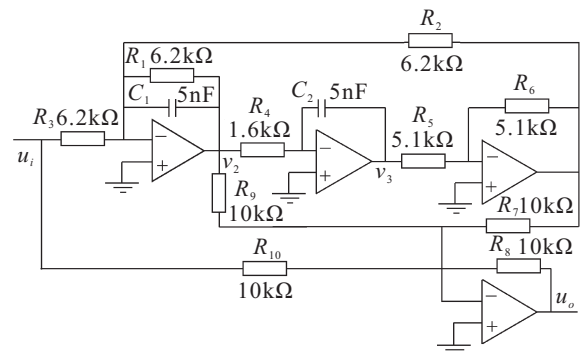


图1 四运放双二阶高通滤波器

例子电路的元件参数和故障类别设定见文献[5],

电阻容差范围为5%, 电容容差范围为10%,  $C_1$ 、 $C_2$ 、 $R_1$ 、 $R_2$ 、 $R_3$ 、 $R_4$  为故障元件. 在例子电路的输入端施加幅值为5 V、持续时间为10  $\mu$ s的脉冲激励, 在电路输出端进行采样获得正常或故障的时域响应信号.

当电阻和电容在各自的容差范围内变化时, 电路为无故障状态; 当电路中的任何一个元件高于或低于其正常值的50% 而其他5个元件在其容差范围内进行变化时, 电路为有故障状态, 并得到相应元件的故障类别.

表1给出了  $C_1$ 、 $C_2$ 、 $R_1$ 、 $R_2$ 、 $R_3$ 、 $R_4$  发生故障时的13个故障类别和对应值. 这13个故障类别包括  $C_1 \uparrow$ 、 $C_1 \downarrow$ 、 $C_2 \uparrow$ 、 $C_2 \downarrow$ 、 $R_1 \uparrow$ 、 $R_1 \downarrow$ 、 $R_2 \uparrow$ 、 $R_2 \downarrow$ 、 $R_3 \uparrow$ 、 $R_3 \downarrow$ 、 $R_4 \uparrow$ 、 $R_4 \downarrow$  和无故障状态 (NF),  $\uparrow$  和  $\downarrow$  分别表示故障值高于和低于正常值50% 时所对应的故障状态.

表1 故障元件的类别及其对应值

故障代码	故障类别	正常值	故障值
SF0	NF	-	-
SF1	$C_1 \uparrow$	5 nF	10 nF
SF2	$C_1 \downarrow$	5 nF	2.5 nF
SF3	$C_2 \downarrow$	5 nF	1.5 nF
SF4	$C_2 \uparrow$	5 nF	15 nF
SF5	$R_1 \uparrow$	6.2 k $\Omega$	15 k $\Omega$
SF6	$R_1 \downarrow$	6.2 k $\Omega$	3 k $\Omega$
SF7	$R_2 \uparrow$	6.2 k $\Omega$	18 k $\Omega$
SF8	$R_2 \downarrow$	6.2 k $\Omega$	2 k $\Omega$
SF9	$R_3 \uparrow$	6.2 k $\Omega$	12 k $\Omega$
SF10	$R_3 \downarrow$	6.2 k $\Omega$	2.7 k $\Omega$
SF11	$R_4 \uparrow$	1.6 k $\Omega$	2.5 k $\Omega$
SF12	$R_4 \downarrow$	1.6 k $\Omega$	0.5 k $\Omega$


### 2.2 特征提取

根据第2.1节所描述的信号采样方法, 对例子电路施加幅值为5 V、持续时间为10  $\mu$ s的脉冲激励信号, 采用如表1所示的元件故障设定值进行PSPICE的蒙特卡罗和参数分析, 在电路的输出端获得每个故障类别的60个故障响应信号. 然后实施小波分析的能量计算<sup>[7,13]</sup>, 最终获得每个故障响应信号的5个候选特征值.


对获得的13个故障类别的  $60 \times 13 = 780$  个样本数据实施第2.2节提出的主元和判别集成分析的特征提取, 得到如图2所示的故障类别分布. 在图2中: PC表示采用PCA分析获得的主元, DC表示采用LDA分析获得的判别元, PDC表示采用PCA+LDA集成方法获得的集成元.

### 2.3 结果分析


为了表明集成方法的优越性和性能比较的合理性, 分别基于PCA方法、LDA方法和PCA+LDA集成方法, 采用最小距离分类器和神经网络实施电路元件的故障分类, 其中神经网络的设计根据文献[10]的计



(a) PCA方法



(b) LDA方法



(c) PCA+LDA集成方法

图2 四运放双极高通滤波器的故障类别分布

算方法确定.

表2给出了采用不同特征提取方法时两种分类器的故障诊断正确率. 根据表2给出的结果, 可以得到以下结论:

- 1) PCA+LDA集成方法的故障识别率明显高于PCA和LDA方法;
- 2) 采用最小距离分类器的目的是为了比较的公平性, 因为最小距离分类器不需要进行任何参数的调节, 具有运算简单、诊断快速的特点;
- 3) 神经网络分类器由于具有自学习和自适应能力, 其故障诊断正确率高于最小距离分类器.

表2 电路元件的故障诊断结果 %

	PCA	LDA	PCA+LDA
最小距离分类器	84.87	87.56	93.33
神经网络分类器	86.25	91.47	97.56

为了表明集成方法与以往文献中研究方法的不同和特点, 基于实际模拟电路在线故障诊断的需要, 表3给出了基于集成方法的神经网络与文献[5-8,11]中神经网络进行性能比较的结果. 由表3可见, 所有的神经网络都具有较好的故障诊断正确率, 不同之处在于网络结构的大小和运算成本的高低:

1) 文献[5]的神经网络分类器具有4个输入节点和16个隐层神经元;文献[6]的小波网络需要4个输入节点和38个隐层小波元;文献[7]的脊波网络需要5个输入节点和30个隐层脊波元;文献[8]的线性脊波网络需要8个输入节点和30个隐层脊波元.显然,与基于集成方法的神经网络相比,这些神经网络均具有更大的网络结构和更高的运算成本.

2) 文献[11]的神经网络与基于集成方法的神经网络相比,尽管具有相同的网络结构和相当的故障诊断性能,但是其特征数固定为2个,当实际电路故障数据的复杂性变高而导致故障类别之间的重叠性增大时,将无法再继续增加更多的特征来提高系统的诊断正确性.集成方法则可以根据故障数据分布的复杂性相应地增多合适的特征元素来实现最终诊断性能的提升.

3) 集成方法是线性化方法,与非线性特征提取方法(如核主元分析)相比,具有较小的计算工作量;基于集成方法的神经网络分类器具有较小的网络结构,在进行网络训练学习和诊断分类时具有更少的计算时间和更低的计算成本.

4) 集成方法的理论分析简单,运算操作方便,计算方法成熟,性能提升明显,不需调整模型参数,显著好于单一特征提取器的提取性能.

表 3 神经网络性能的比较

	输入节点数	隐层节点数	正确分类率/%
文献[5]的方法	4	16	95
文献[6]的方法	5	38	99.59
文献[7]的方法	5	30	99.9
文献[8]的方法	8	30	100
文献[11]的方法	2	5	99
集成方法	2	5	97.56

### 3 结 论

实际模拟电路的在线故障诊断主要关注诊断精度和算法效率.本文针对现代模拟电路故障响应信号所表现出的复杂行为,采用单一PCA或LDA的线性方法,算法实施简单,运行时间短,但具有较低的诊断精度;采用非线性方法特征提取性能较好,但计算过程复杂,运行效率较低;采用PCA+LDA集成方法较好地兼顾了诊断系统的精度和效率,具有较低的计算成本和较高的计算精确度,获得了较好的特征提取性能.PCA+LDA集成分析的特征提取方法对复杂模拟故障诊断算法的有效设计和实际模拟电路的在线诊断具有重要的指导意义.

### 参考文献(References)

[1] 杨士元. 模拟系统的故障诊断与可靠性设计[M]. 北京: 清华大学出版社, 1993: 4-7.

- (Yang S Y. Reliability design and fault diagnosis of analog system[M]. Beijing: Tsinghua University Press, 1993: 4-7.)
- [2] Bandler J W, Salama A E. Fault diagnostic of analog circuits[J]. Proc of IEEE, 1985, 73(8): 1279-1325.
- [3] Spina R, Upadhyaya S. Linear circuit fault diagnosis using neuromorphic analyzers[J]. IEEE Trans on Circuits and Systems II, 1997, 44(3): 188-196.
- [4] Aminian M, Aminian F. Neural-network based analog-circuit fault diagnosis using wavelet transform as preprocessor[J]. IEEE Trans on Circuits System-II, 2000, 47(2): 151-156.
- [5] Aminian F, Aminian M, Collins H W. Analog fault diagnosis of actual circuits using neural networks[J]. IEEE Trans on Instrumentation Measurement, 2002, 51(3): 544-550.
- [6] He Y, Tan Y, Sun Y. Wavelet neural network approach for fault diagnosis of analog circuits[J]. IEE Proc of Circuits Devices System, 2004, 151(4): 379-384.
- [7] 肖迎群, 何怡刚. 基于脊波网络的模拟电路故障诊断[J]. 电工技术学报, 2010, 25(6): 155-162.  
(Xiao Y Q, He Y G. A fault diagnosis method of analog circuit based on ridgelet network[J]. Trans of China Electrotechnical Society, 2010, 25(6): 155-162.)
- [8] Xiao Yingqun, He Yigang. A linear ridgelet network approach for fault diagnosis of analog circuit[J]. Science China Information Sciences, 2010, 53(11): 2251-2264.
- [9] Xiao Yingqun, Feng Lianggui. 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.
- [10] 肖迎群, 冯良贵, 何怡刚. 基于小波分形分析和核判别分析的模拟电路故障诊断方法[J]. 电工技术学报, 2012, 27(8): 230-238.  
(Xiao Y Q, Feng L G, He Y G. A fault diagnosis approach of analog circuit using wavelet-based fractal analysis and kernel LDA[J]. Trans of China Electrotechnical Society, 2012, 27(8): 230-238.)
- [11] Lifan Yuan, Yigang He, Jiaoying Huang, et al. A new neural-network-based fault diagnosis approach for analog circuits by using Kurtosis and entropy as a preprocessor[J]. IEEE Trans on Instrumentation Measurement, 2010, 59(3): 586-595.
- [12] Fukunaga K. Introduction to statistical pattern recognition[M]. New York: Academic, 1990: 445-447.
- [13] Strang G, Nguyen T. Wavelet and filter banks[M]. Cambridge: Wellesley-Cambridge Press, 1996: 122-127.  
(责任编辑: 郑晓蕾)