

DOI:10.19651/j.cnki.emt.1802559

基于 MODWPT 与 LFDA 的模拟电路故障诊断

胡含兵

(湖南师范大学 物理与电子科学学院 长沙 410081)

摘要: 在模拟电路故障诊断过程中,存在故障特征信息提取不充分以及特征信息冗余的问题,对此,提出一种基于最大重叠离散小波包变换(MODWPT)与局部 Fisher 判别(LFDA)的模拟电路故障诊断方法。该方法中,首先利用 MODWPT 进行模拟电路原始信号处理与故障特征提取;随后,针对高维特征集中存在冗余信息,不利于模式识别与分类,利用 LFDA 方法进行降维,获取更有益于故障模式识别的低维特征集;最后,支持向量机(SVM)作为故障模式识别分类器,在此基础上构建模拟电路故障诊断模型。电路仿真实验结果表明,所提出方法的最大故障诊断准确率达 99.17%,从而验证了所提方法的有效性。

关键词: 模拟电路;故障诊断;特征提取;降维;模式识别

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

Analog circuit fault diagnosis based on MODWPT and LFDA

Hu Hanbing

(School of Physics and Electronics, Hunan Normal University, Changsha 410081, China)

Abstract: In the process of fault diagnosis of analog circuits, there are some problems which are insufficient extraction of fault feature information and feature information redundancy, for this, in this paper, a fault diagnosis method for analog circuits based on maximum overlapping discrete wavelet packet transform (MODWPT) and local Fisher discriminant (LFDA) is proposed. In this method, firstly, MODWPT is used to original signal processing and fault features extraction of the analog circuit. Then, due to the redundant information in the high-dimensional feature set, which is not conducive to pattern classification and recognition, LFDA is used to reduce the dimension of the high-dimensional feature set and obtain a lower-dimensional feature set which is more conducive to fault pattern recognition. Finally, support vector machine (SVM) is used as fault pattern recognition classifier, and a fault diagnosis model is constructed based on SVM. Through analog circuit simulation experiments, the maximum fault diagnosis accuracy of the proposed method can reach 99.17%, which verifies the effectiveness of the proposed method.

Keywords: analog circuit; fault diagnosis; features extraction; dimensionality reduction; pattern recognition

0 引言

对于故障模拟电路,在激励信号的作用下,对从电路输出端采样获得的故障响应信号进行分析,确定故障元件以及参数,其实质是一个模式识别与分类问题^[1]。近年来,随着人工智能技术的不断发展,涌现出了许多新的基于模式识别的故障诊断方法,其中,神经网络、决策树以及支持向量机等模式识别分类器已获得广泛应用。在基于模式识别的故障诊断方法中,模拟电路故障特征以及训练的模式识别分类器性能是影响故障诊断准确率的关键因素^[2]。

小波分析是用于模拟电路故障特征提取的常用方法之一^[2]。在基于小波理论的时频分析方法中,最大重叠离散

小波包变换能够克服连续小波变换以及离散小波变换的缺点,可以对信号的高频部分进行很好地分解,而且对于采样频率没有限制,因此它是一种分析非平稳信号的有效方法,将其用于模拟电路故障特征的提取相比小波分析的其他方法能获取更优质的故障特征^[3-4]。文献[5]采用小波包变换获取电路故障特征,用于模拟电路的故障诊断。文献[6]提出基于小波分析与降维算法的模拟电路故障诊断方法,利用小波包变换提取到高维原始特征集,再使用降维算法得到低维特征集用于故障诊断。

随着模拟电路越来越复杂,利用小波分析方法提取到的故障特征往往具有高维且非线性结构特征,高维特征集中存在冗余及干扰特征,降低故障诊断准确率。因此,利用

降维方法从原始高维特征集中得到低维、更有益于模拟电路故障诊断的特征,用于训练模式识别分类器,实现故障诊断。局域线性判别分析(local Fisher discriminant analysis, LFDA)是在经典降维算法线性判别分析(linear discriminant analysis, LDA)的基础上改进而来,为了使降维后的数据更有利于模式识别与分类,LFDA考虑了同类样本数据之间的邻近关系,希望降维过程中,同类样本间距离减小,提高特征空间的可分性^[7-8]。文献[3]中,利用 LFDA 对滚动轴承故障特征集进行降维,从而获取更有益于故障分类的低维特征集用于训练分类器。文献[9]中,将改进的 LFDA 用于处理高维人脸特征集,将得到的低维特征集用于训练模式识别分类器,实现人脸识别。支持向量机(support vector machine, SVM)是一种比较优秀的模式识别方法,具有良好的泛化能力,非常适合解决小样本与高维非线性模式识别问题,其在故障诊断领域中有广泛的应用^[10-16]。

本文基于最大重叠离散小波包变换(maximum overlap discrete wavelet package transform, MODWPT)进行模拟电路故障信号处理与特征提取,构建原始特征集,针对得到的高维特征集,使用 LFDA 进行降维,在降低冗余信息的同时,使同类样本间距离减小,从而得到更有利于故障模式识别与分类的低维特征集。最后,基于 SVM 构建模拟电路故障诊断模型,通过仿真实验,验证 MODWPT 与 LFDA 方法对于故障诊断的有效性,实验结果表明,所提出方法能够提升故障诊断精度,并在选择合适的降维维数下,能够使故障诊断模型达到理想的诊断性能。

1 故障特征提取

最大重叠离散小波变换(maximum overlap discrete wavelet transform, MODWT)是在 DWT 的基础上改进而来,主要由于传统离散小波变换存在以下几方面的局限^[3-4,8]:

1)当被分析信号序列的长度 N 为 2 的整数次幂时,才能进行完整的 DWT;当序列的长度 N 为 2 整数次幂的倍数时,才能进行局部 DWT。

2)DWT 分析的结果会因循环位移而改变,当信号进行相应的循环位移,信号 DWT 的小波系数和尺度系数不能实现相同的循环位移。

3)随着 DWT 分解级数的增加,其尺度系数和小波系数会出现减半,从而影响对系数的统计分析。

针对以上局限,在 DWT 的基础上提出了 MODWT,其不同点在于 MODWT 是一种高冗余度的非正交小波变换,其对信号序列长度 N 没有限制,MODWT 重新定义了低通滤波器(尺度滤波器)和高通滤波器(小波滤波器)MODWT 的变换系数具有平移不变性,各分解层上都具有同样的时间分辨率、不存在相位扭曲等良好性能^[3]。由于 MODWT 不能对高频部分细致分解,则在 MODWT 的基

础上提出了 MODWPT,MODWPT 既保留了 MODWT 的良好性能,又能够进一步分解信号的高频部分^[4]。因此,采用 MODWPT 进行模拟电路的故障信号处理与分析。

模拟电路故障信号经过 MODWPT 分解后,可提取信息熵特征、极值特征或者能量特征等来构建特征向量。其中,能量特征包含了信号的幅值、周期以及频率等电路信号的固有特征信息。对于模拟电路输出响应,其往往为非平稳连续信号,因此,当故障发生时,经 MODWPT 分解得到的小波包各频带信号包含了大量故障特征信息,电路的故障状态被反映在频带能量的变化上^[2]。基于 MODWPT 的故障特征提取可分为以下几步^[3-4]:

1)设定好母小波函数,对故障信号进行 j 层分解,得到一个深度为 j 的满二叉树,第 j 层上共有 2^j 个不同频带信号,提取各频带的分解系数,可表示为: $\{W_j^0, W_j^1, W_j^2, \dots, W_j^{2^j-1}\}$, 其中, $i = 0, 1, 2, \dots, 2^j - 1$ 。

2)分别将得到的分解系数进行重构,得到重构信号 $\{S_{j0}, S_{j1}, S_{j2}, \dots, S_{j2^j-1}\}$, 其中, $i = 0, 1, 2, \dots, 2^j - 1$ 。

3)计算重构信号 S_{ji} 的总能量 E_{ji} :

$$E_{ji} = \int |s_{ji}(t)|^2 dt = \sum_{k=1}^n |X_{ik}|^2 \quad (1)$$

式中: X_{ik} ($k = 1, 2, \dots, n$) 表示重构信号 S_{ji} 的离散点幅值。

4)构建原始故障特征向量,将第 j 层各小波包节点得到的重构信号的能量作为特征向量 T :

$$T = [E_{j0}, E_{j1}, E_{j2}, \dots, E_{j(2^j-1)}] \quad (2)$$

2 LFDA 算法

LDA 的降维过程是为了寻找一个最佳的投影方向,让高维数据按照这个方向进行投影,使不同类别样本数据间距离增大,同类样本数据尽可能靠拢,使降维后的低维数据有利于分类^[9-11]。但 LDA 未将数据间局部关系考虑到降维过程中,从而不利于多模数据的处理。LFDA 在 LDA 的基础上,考虑了同类样本数据之间的邻近关系,从而使得降维后的数据更有利于分类。LFDA 降维过程的详细描述如下^[7]:

定义向量 $x_i \in \mathbf{R}^m$ 为训练集 $X \in \mathbf{R}^{m \times n}$ 的第 i 列向量,在 $\mathbf{R}^{m \times n}$ 中 n 是样本数量, m 是样本维数,由此训练集 X_i 表示属于第 i ($i = 1, 2, \dots, c$) 类样本子集, X_i 的样本数目为 n_i , 则有:

$$\sum_{i=1}^c n_i = n \quad (3)$$

式中: n 为样本类总数。样本标签 $\mathbf{Y} = \{y_1, y_2, \dots, y_n\}$, ($y_i \in 1, 2, \dots, c$)。

LDA 的类间散度矩阵 \mathbf{S}_b 与类内散度矩阵 \mathbf{S}_w 的表达式如下:

$$\mathbf{S}_b = \frac{1}{2} \sum_{i,j=1}^c p_{ij}^b (x_i - x_j)(x_i - x_j)^T = \mathbf{X}(\mathbf{D}^b - \mathbf{P}^b)\mathbf{X}^T \quad (4)$$

$$S_w = \frac{1}{2} \sum_{i,j=1}^n \hat{p}_{ij}^w(x_i - x_j)(x_i - x_j)^T = \mathbf{X}(\mathbf{D}^w - \mathbf{P}^w)\mathbf{X}^T \quad (5)$$

在式(4)与(5)中,

$$\hat{p}_{ij}^b = \begin{cases} 1/n - 1/n_i, & y_i = y_j = l \\ 1/n & y_i \neq y_j \end{cases} \quad (6)$$

$$\hat{p}_{ij}^w = \begin{cases} 1/n_i, & y_i = y_j = l \\ 0 & y_i \neq y_j \end{cases} \quad (7)$$

在式(6)与(7)中, $\mathbf{P}^b = [\hat{P}_{ij}^b]_{n \times n}$ 和 $\mathbf{P}^w = [\hat{P}_{ij}^w]_{n \times n}$ 为权重矩阵, \mathbf{D}^b 与 \mathbf{D}^w 为对角矩阵。

在多类 LDA 中,数据投影的低维空间为一个超平面,假定超平面空间的维度为 $d (d < c)$, $\{\omega_1, \omega_2, \omega_3, \dots, \omega_d\}$ 为对应的基向量并组成映射矩阵 \mathbf{W} 。LDA 的降维优化目标为:

$$J(\mathbf{W}) = \max_{\mathbf{W}} \frac{|\mathbf{W}^T \mathbf{S}_b \mathbf{W}|}{|\mathbf{W}^T \mathbf{S}_w \mathbf{W}|} \quad (8)$$

LFDA 则在 LDA 的基础上,将同类样本数据之间的邻近关系,LFDA 拥有与 LDA 相同的降维优化框架,其中的类内散度矩阵 $\tilde{\mathbf{S}}_b$ 与类间散度矩阵 $\tilde{\mathbf{S}}_w$ 分别修改为:

$$\tilde{\mathbf{S}}_b = \frac{1}{2} \sum_{i,j=1}^n \tilde{\hat{p}}_{ij}^b(x_i - x_j)(x_i - x_j)^T = \mathbf{X}(\tilde{\mathbf{D}}^b - \tilde{\mathbf{P}}^b)\mathbf{X}^T \quad (9)$$

$$\tilde{\mathbf{S}}_w = \frac{1}{2} \sum_{i,j=1}^n \tilde{\hat{p}}_{ij}^w(x_i - x_j)(x_i - x_j)^T = \mathbf{X}(\tilde{\mathbf{D}}^w - \tilde{\mathbf{P}}^w)\mathbf{X}^T \quad (10)$$

在式(9)与(10)中,

$$\tilde{\hat{p}}_{ij}^b = \begin{cases} A_{i,j}(1/n - 1/n_i), & y_i = y_j = l \\ 1/n & y_i \neq y_j \end{cases} \quad (11)$$

$$\tilde{\hat{p}}_{ij}^w = \begin{cases} A_{i,j}(1/n_i), & y_i = y_j = l \\ 0 & y_i \neq y_j \end{cases} \quad (12)$$

其中,

$$A_{i,j} = \exp\left(-\frac{\|x_i - x_j\|^2}{\gamma_i \gamma_j}\right) \quad (13)$$

其中, $\gamma_i = \|x_i - x_i^k\|$, x_i^k 是 x_i 的第 k 个最近邻。如果 x_i 与 x_j 在特征空间中越邻近,则 $A_{i,j}$ 的值将增大,反之 $A_{i,j}$ 的值将减小。

3 基于 MODWPT 与 LFDA 的模拟电路故障诊断框架

本文所提出的模拟电路故障诊断框架如图 1 所示,整个框架包括:训练与测试 2 个阶段,每个阶段有 3 个步骤:故障信号处理与特征提取、特征降维和故障诊断。第 1 步中,模拟电路故障信号经 MODWPT 分解与重构,得到终端节点的重构信号,再计算重构信号能量,构成原始特征集;第 2 步中,训练阶段中,对于得到的高维特征集,利用 LFDA 方法进行降维,得到低维特征集,并得到降维映射矩阵;对于测试阶段的高维特征集,直接利用训练阶段得到的降维映射矩阵进行降维,得到低维测试特征集;第 3 步中,

将从训练样本中得到的低维特征集用于训练 SVM 分类器,得到训练好的分类器则直接进行测试样本的故障诊断。

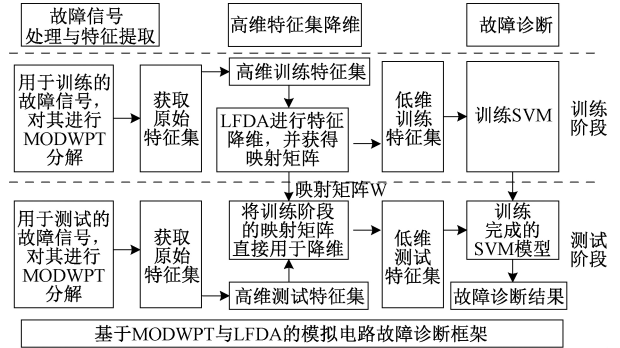


图 1 基于 MODWPT 与 LFDA 的模拟电路故障诊断框架

4 仿真实验分析

4.1 实验设置

本文采用国际标准电路中 CSTV 滤波器^[5]作为仿真实例,电路如图 2 所示。电路中各元件参数值设置为元件的标称值,其中, $R_1 = R_2 = R_3 = R_4 = R_5 = 10 \text{ k}\Omega$, $R_6 = 3 \text{ k}\Omega$, $R_7 = 7 \text{ k}\Omega$, $C_1 = C_2 = 20 \text{ nF}$, 对于电阻与电容的容差范围,分别设置为 $\pm 5\%$ 和 $\pm 10\%$ 。在该电路中设置故障元件分别为 R_1, R_2, R_5, C_1, C_2 , 对此电路施加测试激励为 $V_1 = 1 \text{ V(AC)}$, 上升时间为 $0.1 \mu\text{s}$, 宽度 $10 \mu\text{s}$, 周期为 $3 \mu\text{s}$ 的脉冲信号。本文中只考虑单故障情况,根据故障元件的设置,加上电路正常状态,共有 11 种电路状态,即作为 11 种故障模式。具体设置如表 1 所示。




图 2 CSTV 滤波电路

表 1 模拟电路故障模式

故障类别	标称值	故障值	故障编号
正常状态	—	—	F1
$R_1 \uparrow (+5\%)$	10 kΩ	10.5 kΩ	F2
$R_1 \downarrow (-5\%)$	10 kΩ	9.5 kΩ	F3
$R_2 \uparrow (+5\%)$	10 kΩ	10.5 kΩ	F4
$R_2 \downarrow (-5\%)$	10 kΩ	9.5 kΩ	F5
$R_5 \uparrow (+5\%)$	10 kΩ	10.5 kΩ	F6
$R_5 \downarrow (-5\%)$	10 kΩ	9.5 kΩ	F7
$C_1 \uparrow (+10\%)$	20 nF	22 nF	F8
$C_1 \downarrow (-10\%)$	20 nF	18 nF	F9
$C_2 \uparrow (+10\%)$	20 nF	22 nF	F10
$C_2 \downarrow (-10\%)$	20 nF	18 nF	F11

本文利用 Cadence 17.2 电路软件对 CSTV 滤波器电路按照所设置的故障模式,进行仿真实验,实验对每种故障模式做 100 次蒙特卡洛分析,从电路测点 OUT 处,可得到 1 100 组样本数据,从每种故障模式的样本数据中随机抽取 60 组作为训练样本,剩余 40 组作为测试样本。随后,利用训练样本与测试样本进行实验分析。

4.2 结果分析

本文采用 MODWPT 处理原始模拟电路故障信号,针对小波分解层次越高,包含信息越多的特点。在本文实验中,选用“db5”小波进行 5 层分解,得到 32 个终端节点的重构信号,并计算重构信号能量,构建原始特征集。虽然经 MODWPT5 层分解后可以提取到更多的故障特征,但是随着特征集维度的增大,也会存在冗余特征,从而不适合直接输入模式识别分类器进行故障识别。因此,将原始特征集进行 LFDA 降维处理后,在降低特征集冗余信息的同时得到一个更有益于分类的低维特征集。对于模式识别分类器,选用被广泛运用的 SVM,构建 MODWPT-LFDA-SVM 模拟电路故障诊断模型。本文为验证 MODWPT 方法以及降维方法 LFDA 用于模拟电路故障诊断的有效性,设置对比模型 MODWPT-SVM、WPT-SVM 与 WPT-LFDA-SVM,将原始故障信号经 WPT 处理,构建对比模型 WPT-LFDA-SVM。其中,MODWPT-SVM 与 WPT-SVM 模型是将原始信号经处理与特征提取后直接输入故障模式识别分类器,进行故障诊断。如表 2 所示,在未使用降维方法情况下,MODWPT-SVM 与 WPT-SVM 模型的诊断结果分别为 97.54% 与 92.17%,说明使用 MODWPT 方法相比 WPT 能够提升故障诊断准确率。

表 2 未使用降维方法的模拟电路故障诊断结果

MODWPT-SVM	WPT-SVM
故障诊断准确率/%	故障诊断准确率/%
97.54	92.17

表 3 所示为使用了降维方法 LFDA 的故障诊断结果,从表中可以看出,故障诊断准确率会受到降维维数的影响,降维维数的增大在一定程度上提高了诊断准确率,同时还验证了使用 MODWPT 方法的故障诊断模型相比使用 WPT 的模型具有更高的诊断准确率。本文所提出的 MODWPT-LFDA-SVM 模型的最大故障诊断准确率能够达到 99.17%。

表 3 使用降维方法的模拟电路故障诊断结果

降维 维数	MODWPT-LFDA-SVM 故障诊断准确率/%	WPT-LFDA-SVM 故障诊断准确率/%
5	94.79	89.58
10	98.33	95.71
15	98.85	96.67
20	99.17	96.67
25	99.17	97.29

5 结 论

本文在对小波分析与特征降维方法 LFDA 的研究基础上,提出一种基于 MODWPT 与 LFDA 的模拟电路故障诊断框架,基于 SVM 构建故障诊断模型 MODWPT-LFDA-SVM。在该框架中,利用 MODWPT 对原始故障信号进行处理,提取故障特征,构建原始特征集。为降低高维特征集中存在的冗余信息,提高特征集对于不同故障模式的可分性,提高故障诊断准确率,利用 LFDA 处理高维特征集,得到更有益于故障模式识别的低维特征集。为验证 MODWPT 以及 LFDA 对于模拟电路故障诊断的有效性,设置对比模型 MODWPT-SVM、WPT-SVM 与 WPT-LFDA-SVM。最后利用 CSTV 标准电路,设置故障模式,测试各模型的故障诊断准确率。实验结果表明,使用 MODWPT 的模型比使用 WPT 的模型具有更高的故障诊断准确率,LFDA 在不同的降维维数下对模型的故障诊断性能具有不同的影响,在选择合适的降维维数时,故障诊断模型能够达到理想的故障诊断准确率。

参考文献

- [1] 马峻,赵飞乐,徐潇,等.MRA-PCA-PSO 组合优化 BP 神经网络模拟电路故障诊断研究[J].电子测量与仪器学报,2018,32(3):73-79.
- [2] 孙业胜.基于优选小波包的模拟电路故障深度特征提取方法[D].合肥:合肥工业大学,2017.
- [3] 俞啸.数据驱动的滚动轴承故障特征分析与诊断方法研究[D].徐州:中国矿业大学,2017.
- [4] 杨宇,何怡刚,程军圣,等.用最大重叠离散小波包变换的 Hilbert 谱时频分析[J].振动、测试与诊断,2009,29(1):10-13,114.
- [5] 胡鸿志,岑德炼,吴汝琴,等.基于小波包和 BAGRNN 的模拟电路故障诊断方法[J].微电子学与计算机,2018,35(4):42-45,52.
- [6] 马玉莹.基于数据降维算法的模拟电路故障诊断应用研究[D].北京:北方工业大学,2018.
- [7] SUGIYAMA M. Dimensionality Reduction of Multimodal Labeled Data by Local Fisher Discriminant Analysis[M]. JMLR.org, 2007.
- [8] ALVES D, COSTA F, RIBEIRO R, et al. Real-time power measurement using the maximal overlap discrete wavelet-packet transform [J]. IEEE Transactions on Industrial Electronics, 2016(99):1-1.
- [9] 齐鸣鸣,向阳.基于 MB-LBP 和改进的 LFDA 的人脸识别[J].计算机科学,2012,39(6):266-269.
- [10] 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.
- [11] 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.

- [12] 吴世浩, 孟亚峰. 非线性模拟电路故障诊断方法综述[J]. 飞航导弹, 2017(9):60-64.
- [13] 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.
- [14] 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.

- [15] 吕洪爽, 何玉珠. 基于 CBA-SVM 的模拟电路故障诊断方法研究[J]. 电子测量技术, 2018, 41(7):6-10.
- [16] 何威, 何怡刚, 罗旗舞, 等. 基于连续小波奇异熵的模拟电路故障诊断新方法[J]. 电子测量与仪器学报, 2017, 31(12):1967-1973.

作者简介

胡含兵(通信作者), 硕士研究生, 主要研究方向为电路与系统、模拟电路故障诊断。

E-mail:1103394281@qq.com