

选取累计方差贡献率达到 90% 以上的前 r 个特征值对应的特征向量构成特征子^[4]。

1.2 小波包分析法

与小波分析相比较,小波包可以对其没有完成细分的高频部分进行进一步分解,从而精确地刻画出信号在各个频带下的局部信息,更有效的提取电路的故障特征^[5]。因此,小波包变换可以将各频带上变化不明显的频率特征以显著的能量变化形式表现出来,再据此能量构造各故障模式下的特征向量。具体步骤如下:

- 1) 对输出信号 s 进行 n 层小波包分解,提取共 2^n 个小波包分解系数 X_i 。
- 2) 依据各个小波包系数,重构各频带信号 S_i 。

$$S = \sum_{i=0}^{2n-1} S_i \quad (3)$$

- 3) 计算各频带信号的总能量。 E_i 表示 S_i 的能量。则:

$$E_i = \int |S_i|^2 dt = \sum_{k=1}^N |x_i(k)|^2 \quad (4)$$

其中: $x_i(k)$ 为 S_i 的离散点的幅值,频带内信号个数(长度)为 N 。

- 4) 根据 E_i 构造一个以能量为元素的特征向量 T , 并进行归一化处理^[6]。

$$T = [E_0, E_1, \dots, E_{2n-1}]$$

归一化后,

$$t = [E_0, E_1, \dots, E_{2n-1}]$$

其中,

$$E_i = E_i/E \quad E = \left(\sum_{j=0}^{2n-1} |E_j|^2 \right)^{1/2} \quad (5)$$

1.3 最优小波基的选择

在进行小波包分解时,小波基函数的种类对分解结果有很大的影响。因此,所选的小波基是否最佳对特征提取的重要性不言而喻。特征偏离度 D_b 表示的是故障特征与正常状态特征之间的偏离程度。本文将以此作为选择标准来确定最优小波基^[7]。

$$D_b = \sum_{i=1}^S \sum_{j=1}^N P_i(m_j^i - m_j) (m_j^i - m_j)^T \quad (6)$$

P_i 表示第 i 类故障特征的先验概率, m_j^i 表示第 i 类故障特征样本集中的第 j 个数据, m_j 表示正常状态样本集第 j 个数据。特征偏离度越大,说明该小波基函数分解得到的故障特征更加有效。

2 基于信息融合的特征提取和融合方法

小波包变换和主元分析从不同角度对输出信号进行特征提取,为了能够更加充分和全面的利用故障样本中所包含的信息,避免使用单一方法所带来的不足,文中将两种方法并行应用,并对提取到的特征进行有效的融合,以达到更佳分类效果。图 1 是特征提取与融合的过程框图。

具体方法步骤如下:

- 1) 对待诊断电路用 Mutisim 软件进行建模,进行灵敏度分析,选择灵敏度较大的元件进行故障设置。
- 2) 对采集到样本数据进行预处理,将其与标准响应信号做差,得到差值信号^[8]。

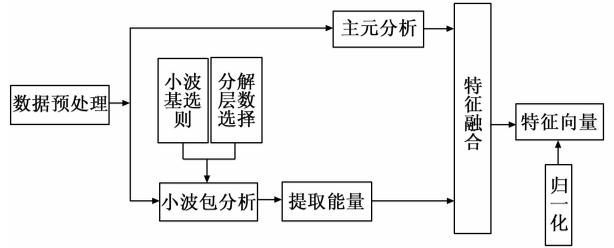


图 1 特征提取与融合框图

原始样本数据为 $X = (x_1, x_2, \dots, x_n)$, 无故障标准信号的数据样本为 $(x_s)_{m \times 1}$, m 为样本维数, n 为样本个数, 则预处理后样本为 $X_d = (x_1 - x_s, x_2 - x_s, \dots, x_n - x_s)$ 。

- 3) 对差值信号进行 PCA 特征提取, 根据主成分贡献率选择合适的元元个数, 构建新的特征向量。主元个数的选取要适中, 过多或过少都不利于对信号的特征提取。

- 4) 对差值信号进行小波包能量提取。首先确定最优小波基函数以及分解层数, 计算各个频带的能量并归一化, 构成特征向量。

- 5) 将 PCA 特征和小波能量特征进行融合, 形成融合后的特征向量, 并对其进行归一化处理, 送入分类器进行诊断。本文提出了三种不同的融合模型, 同时还研究了不同融合模型因子 μ 对结果产生的影响。

假定 PCA 选取的主元个数为 r , 最终构成了一个 r 维特征向量 $a = [a_1, a_2, \dots, a_r]^T$; 小波包分解层数为 n , 最终提取的能量特征向量为 t 维, 即特征向量 $b = [b_1, b_2, \dots, b_t]^T$; 分别验证以下三种融合模型结果。设融合后特征向量为 c 。其中, $0 < \mu < 1, \beta = 1 - \mu$ 。

- 1) 整体间隔模型:

$$c = [\mu a, \beta b]^T = \begin{bmatrix} \mu a \\ \beta b \end{bmatrix}$$

- 2) 单间隔模型:

$$c = \begin{cases} [\mu a_1, \beta b_1, \mu a_2, \beta b_2, \dots, \mu a_r, \beta b_r]^T & (r = t) \\ [\mu a_1, \beta b_1, \mu a_2, \beta b_2, \dots, \mu a_i, \beta b_i, \mu a_{i+1}, \dots, \mu a_r]^T & (r > t) \\ [\mu a_1, \beta b_1, \mu a_2, \beta b_2, \dots, \mu a_r, \beta b_r, \beta b_{r+1}, \dots, \beta b_t]^T & (r < t) \end{cases}$$

- 3) 双间隔模型:

$$c = \begin{cases} [\mu a_1, \mu a_2, \beta b_1, \beta b_2, \dots, \beta b_t]^T & (r = t) \\ [\mu a_1, \mu a_2, \beta b_1, \beta b_2, \dots, \beta b_i, \mu a_{i+1}, \dots, \mu a_r]^T & (r > t) \\ [\mu a_1, \mu a_2, \beta b_1, \beta b_2, \dots, \beta b_{r-1}, \beta b_r, \dots, \beta b_t]^T & (r < t) \end{cases}$$

为了避免数据大小不平衡带来的不利影响, 同时保证下一步分类快速方便, 将融合后特征向量 c 进行归一化处理得到 c^* , 将其变为 $[0, 1]$ 之间数据, 归一化方法如下^[9]:

$$c_i^* = \frac{c_i - c_{\min}}{c_{\max} - c_{\min}} \quad i = 1, 2, \dots, r + t$$

c_{\max} 表示样本 c_i 中最大值, c_{\min} 表示样本 c_i 中最小值。

3 仿真实证

本文中实验举例选用国际标准的测试电路 Sallen-Key 带通滤波器电路进行验证。按照上述故障特征提取和融合方法完成后, 送入神经网络分类器进行故障诊断并验证结果。本文中使用的仿真软件为 Mutisium10.0, 算法的实现由 Matlab

R2013a 完成。图 2 为 Mutisium 仿真的电路图模型。

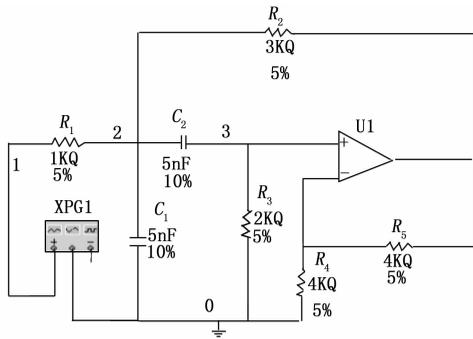


图 2 带通滤波器电路图模型

其中各个元件的标称值分别为 $R_1 = 1 \text{ k}\Omega$, $R_2 = 3 \text{ k}\Omega$, $R_3 = 2 \text{ k}\Omega$, $R_4 = R_5 = 4 \text{ k}\Omega$, $C_1 = C_2 = 5 \text{ nF}$ 。电阻的容差为 5%, 电容的容差为 10%。节点 1 为输入激励点, 节点 5 为唯一输出响应点。实验中, 激励信号选择基频为 10 kHz, 幅值为 5 V, 占空比 10% 的方波信号。下面按照实验步骤进行实验验证:

1) 首先进行灵敏度分析^[10], 从而确定故障集。图 3 是各个元件对输出响应点 5 的灵敏度仿真分析结果图。

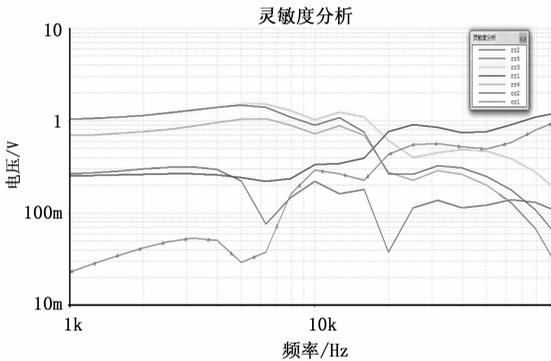


图 3 灵敏度分析结果图

图中横、纵坐标分别为频率和输出响应电压。通过灵敏度分析可以看出 R_2 , R_3 , C_1 , C_2 灵敏度较高。因此选取故障集包括 $R_2 \uparrow$, $R_2 \downarrow$, $R_3 \uparrow$, $R_3 \downarrow$, $C_1 \uparrow$, $C_1 \downarrow$, $C_2 \uparrow$, $C_2 \downarrow$ 和正常模式共 9 种故障模式, 令正常模式为 M_0 , 其余依次为 $M_1 - M_8$ 。表示元件参数在 $[+5\% (+10\%), +50\%]$ 之间, 表示元件参数在 $[-5\% (-10\%), -50\%]$ 之间。本文中在进行故障设置时, 统一将其偏离幅度设置为 50%。

2) 在 Multisim10.0 仿真环境下分别对各种故障模式进行 40 次蒙特卡洛分析, 得到原始采样数据。其中 25 次用于训练, 15 次用于测试。图 4 是时 40 次蒙特卡洛仿真分析图。其中元件参数变化服从高斯分布。

这样得到的是一个连续的响应曲线。为了便于分析和处理, 我们对其进行采样, 一共采集 200 个点, 得到一个规模为 200×360 原始数据。然后与标准信号做差, 得到差值信号, 留待下一步分析。

3) 对信号进行特征提取。

(1) 对差值信号进行 PCA 特征提取。在 Matlab 中对预处理后的样本数据进行主元分析, 所利用的程序代码如下:

```
[coeff, score, latent, tsquared, explained] = pca (P)
```

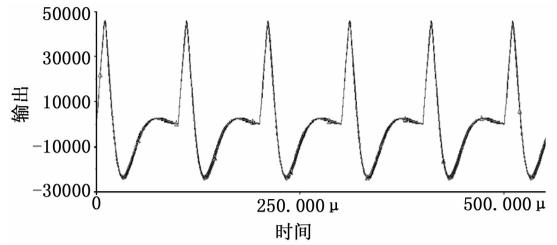


图 4 $R_2 \downarrow$ 时 40 次蒙特卡洛图

其中, P 为样本数据矩阵, $latent$ 为特征值矩阵, $score$ 主成分分数, $explained$ 主元方差贡献率。

通过分析发现, 当主元个数为 8 时, 累计主元贡献率已达 99.1%, 远远超过 90%。所以 PCA 提取的特征向量样本维数为 8 即可。

(2) 对差值信号进行小波包能量提取。首先根据公式 (6) 进行最优小波包选取, 本文选择 Haar、db2、db3 三种小波基函数进行特征偏离度计算。部分结果如表 1。

表 1 不同小波基特征偏离度

| 基 | $R_2 \uparrow$ | $R_3 \downarrow$ | $C_1 \uparrow$ | $C_2 \downarrow$ |
|------|----------------|------------------|----------------|------------------|
| Haar | 0.0659 | 5.2957 | 0.3305 | 0.022 |
| db2 | 0.0951 | 7.6689 | 0.4777 | 0.0314 |
| db3 | 0.1097 | 8.8667 | 0.5521 | 0.0365 |

从表中可以看出, db3 小波基特征偏离度明显大于前两种, 因此本文选择 db3 小波基函数。

利用 Matlab 小波工具箱中 db3 小波基函数对预处理信号进行 3 层小波包能量特征提取, 分别计算出 8 个频带内的能量, 归一化后得到 8 维特征向量^[11]。主要程序代码如下:

```
clear;
clc;
t=wpdec(x,3,'db3','shannon');
plot(t);
for i=1:8;
cfs=wpcoef(t,[3,i-1]);
rcfs=wprcoef(t,[3,i-1]);
E(i)=norm(rcfs.^2)
end
[e,ps]=mapminmax(E)
```

图 5 为小波包分解结构和节点 (3, 1) 的信号波形图。

4) 对提取到的两类特征向量分别按照本文提出的三种模型进行融合, 得到最终的故障特征向量。采用三层 BP 神经网络进行故障诊断, 并利用附加动量法对其进行改进。根据融合后特征向量维数确定输入层节点数为 16, 输出层节点数为 4 (采用二进制编码法), 隐层神经元个数根据经验公式 $l = \sqrt{m+n} + a$ 确定, m, n 分别为输入层以及输出层的节点数, a 为 0-10 的常数。经过不断的实验测试, 最终取 $l = 14$ 。学习速率设为 0.3, 目标误差设为 0.01, 附加的动量因子设取 0.9, 神经网络分类器建立、训练、仿真依次使用如下程序代码^[12]。

```
建立:
net=newff (PR, [14, 4], {'tansig' 'logsig'},'
```

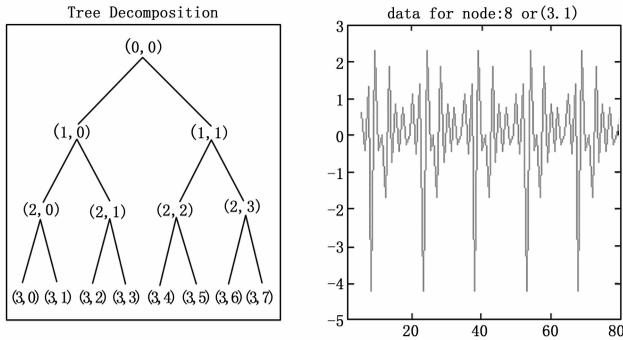


图 5 三层小波包分解树

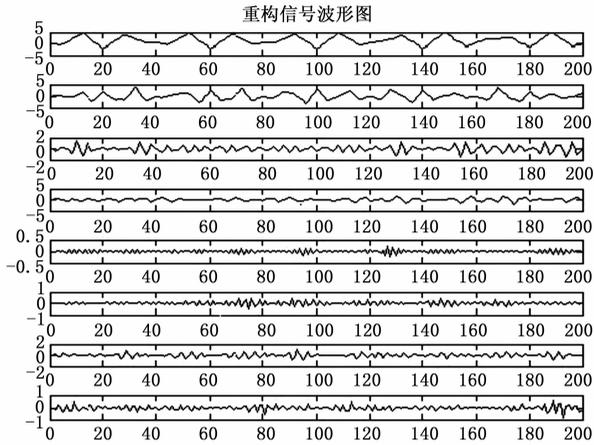


图 6 重构信号波形图

trainingdm');

训练: [net, tr] = train (net, P, T);

仿真: y = sim (net, P);

利用 225 组训练数据对神经网络进行训练学习, 然后用另外 135 组测试数据进行结果验证。各种故障模式下神经网络期望的二进制输出如表 2 所示。

表 2 神经网络期望输出二进制表

| 状态 | M0 | M1 | M2 | M3 | M4 | M5 | M6 | M7 | M8 |
|----|----|----|----|----|----|----|----|----|----|
| 期 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 |
| 望 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 | 0 |
| 输 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 1 | 0 |
| 出 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 |

5) 仿真结果对比分析。

下表是不同融合模型因子对应的诊断正确率。

表 3 不同融合因子对应诊断正确率 %

| μ | 0.4 | 0.43 | 0.45 | 0.47 | 0.49 | 0.6 |
|-------|-------|------|------|------|------|------|
| 整 | 83.4 | 86. | 88.2 | 88.1 | 85.9 | 82.1 |
| 单 | 89.3 | 90.5 | 90.7 | 90.6 | 89.3 | 85.5 |
| 双 | 85.28 | 88.2 | 89.0 | 88.1 | 87.2 | 84.6 |

融合因子 μ 越大, 说明 PCA 特征在融合后特征向量中占比越多。从表中可以看出, μ 过大或过小都不会有最佳融合效果, 当在 0.46 左右时, 每种模型的诊断正确率都达到高。而相对比较, 单间隔模型诊断正确率最高。

下表是 $\mu=0.46$, 时, 各种诊断方法正确率对比结果, 特征融合采用单间隔模型。

表 4 测试样本诊断结果对比

| 状态 | 总数 | PCA | | 小波包 | | 特征融合 | |
|------|-----|------|-------|------|-------|------|-------|
| | | 正确数 | 正确率/% | 正确数 | 正确率/% | 正确数 | 正确率/% |
| M0 | 15 | 15 | 100 | 15 | 100 | 15 | 100 |
| M1 | 15 | 12 | 80 | 11 | 73 | 13 | 87 |
| M2 | 15 | 10 | 67 | 11 | 73 | 14 | 93 |
| M3 | 15 | 13 | 87 | 14 | 93 | 14 | 93 |
| M4 | 15 | 11 | 73 | 12 | 80 | 14 | 93 |
| M5 | 15 | 13 | 87 | 14 | 93 | 14 | 93 |
| M6 | 15 | 14 | 93 | 13 | 87 | 15 | 100 |
| M7 | 15 | 12 | 80 | 13 | 87 | 14 | 93 |
| M8 | 15 | 11 | 73 | 12 | 80 | 13 | 87 |
| 总 | 135 | 111 | 82 | 115 | 85 | 126 | 93 |
| 时间/s | | 0.24 | | 0.25 | | 0.43 | |

可以看出, 虽然诊断时间变长, 特征融合模型的诊断正确率明显高于其单独使用时的诊断正确率。对于实时性要求不是非常高的模拟电路故障诊断来说, 这种方法还是很有意义的。

4 结论

本文利用信息融合的思想, 采用了主元分析与小波包分析并行提取故障特征的方法, 并按照三种不同的融合模型进行了特征向量的融合。通过设计改进的神经网络分类器模型来对融合后特征向量进行故障诊断与结果验证。通过仿真计算, 结果表明, 该方法可以有效提高故障诊断正确率。

参考文献:

- [1] 唐静远. 模拟电路故障诊断的特征提取及支持向量机集成方法研究 [D]. 成都: 电子科技大学, 2009.
- [2] 廖 薇, 许春冬, 刘锦高. 基于神经网络的模拟电路故障诊断研究 [J]. 微电子学与计算机, 2010, 27 (5).
- [3] Aminan M, Aminan F. Neural network based analog-circuit fault diagnosis using wavelet transform as preprocessor [J]. IEEE Trans on Circuits Syst-II, 2000, 44 (3): 151-156.
- [4] 陈绍炜, 吴敏华, 赵 帅. 基于 PCA 和 ELM 的模拟电路故障诊断 [J]. 计算机工程与应用, 2015, 51 (11).
- [5] 谢 涛. 基于 (多) 小波 (包)、神经网络及优化的模拟电路故障诊断研究 [D]. 长沙: 湖南大学, 2011.
- [6] 孙永奎. 基于支持向量机的模拟电路故障诊断方法研究 [D]. 成都: 电子科技大学, 2009.
- [7] 何 星, 王宏力, 陆敬辉. 基于优选小波包和 ELM 的模拟电路故障诊断 [J]. 仪器仪表学报, 2013, 34 (11): 14-19.
- [8] 吴明岩. 基于信息融合的模拟电路故障诊断研究 [D]. 大连: 大连理工大学, 2011.
- [9] 唐圣学, 蔡红军, 李志刚. 基于小波与神经网络的模拟电路故障诊断融合方法 [J]. 2015, 46 (1).
- [10] 刘美容, 张立玮. 基于小波分解和模糊聚类的模拟电路软故障诊断 [J]. 微电子学与计算机, 2014, 31 (12).
- [11] 潘 强, 熊 波. 基于灵敏度特性函数的特征提取与故障诊断 [J]. 电子测量技术, 2014 (1): 122-126.
- [12] 吴 凡, 张 莉. 基于小波神经网络的模拟电路故障诊断技术 [J]. 计算机测量与控制, 2014, 22 (11).