电路故障模式的信息融合方法研究

电子产品的可靠性越来越受到重视，针对电子产品故障诊断和推理领域出现的问题，以基于仿真的故障电路信号为对象，深入研究了用于故障模式识别的信息融合方法，建立了故障电路信息融合模型，提出了针对神经网络的基本概率分配函数，丰富了DS证据理论的应用范围，实现了电路的故障模式识别，为向更高层的故障推理提供支持。

段开来／中国电子科技集团公司第十研究所

段开来／助理工程师

关键词／Keywords
可靠性·
故障模式·
信息融合·

0 引言

随着科技发展，电子产品向着结构日益复杂、功能日益先进、体积缩小和系统集成度日益提高的方向发展，因而人们对系统可靠性的重视程度也越来越高，尤其在军用产品方面，对产品可靠性的要求更加严格。

当前电路系统底层的诊断和判定问题已经得到很好的解决，而在故障向上推理和传播的过程中还有一些问题需要解决：电路中故障信号种类繁多且数据量大，给故障模式的识别带来难度；由于元器件故障模式太多、仿真时间过长和模型规模过大等原因，还无法将故障的影响传递到上层。与此同时，信息融合技术成为当前研究的热点，它基于各种信息源的分离观测信息，利用特定的算法，通过对信息的优化组合导出更多的有效信息，最终利用多个信息源共同或联合操作的优势来提高整个系统的有效性，为模式识别和故障推理开辟了新的途径。

本文针对EDA电路故障仿真建立了信息融合模型，结合DS证据理论和神经网络等方法进行故障诊断，并完善诊断知识库，为向更高层的故障推理提供支持。

1 故障电路信息融合模型

本文引入信息融合理论的目的是将电路板的故障模式分类、融合，归并为典型的、有代表意义的少量故障模式，从而大大减少故障仿真的工作量，有利于将故障模式的影响向上层传递。通过建立并维护故障信号的融合模型，将故障仿真抽象为模式识别工具，为故障诊断开辟了新的思路。

信息融合模型如图1所示。模型主要针对系统的属性信息展开融合，包括数据层、特征层和决策层融合。其中数据层融合将全部传感器的观测数据融合，然后从融合的数据中提取特征向量。根据电路仿真的信号特点主要对信号进行

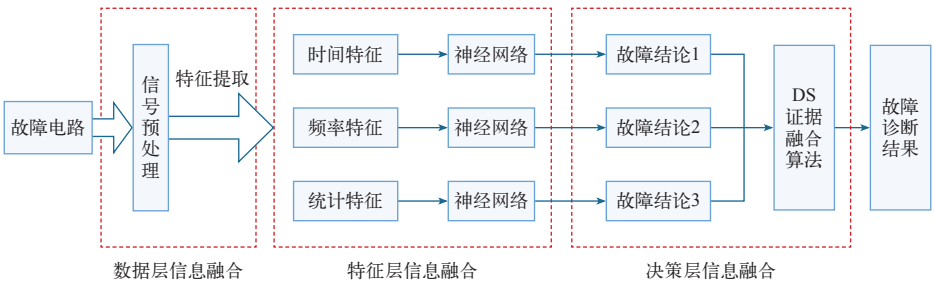

图1 信息融合模型

预处理；特征层融合提供从观测数据中提取的有代表性的特征，并融合成单一的特征向量，然后运用模式识别的方法进行处理。本文选用时间、频率和统计特征，分别利用自组织特征映射型的神经网络进行特征融合；决策层融合是指在每个传感器对目标做出识别后，将多个传感器的识别结果进行融合，本文选用DS证据理论进行融合，给出故障诊断的结果。

2 神经网络

人工神经网络是从微观结构与功能上对人脑神经系统的模拟而建立起来的具有模拟人的部分形象思维能力的模型，在神经网络中有一类无导师的自组织神经网络，通过对自身训练，自动对输入模式进行分类。自组织特征映射网络（Self Organizing Feature Map，SOM）也称Kohonen网络，是自组织神经网络中的一种，是一个由全连接的神经元阵列组成的无导师、自组织和自学习网络，处于空间中不同区域的神经元有着不同的分工。当一个神经网络接受外界输入模式时，将会分为不同的反应区域，各区域对输入模式具有不同的响应特性。

SOM的结构图如图2所示，除了没有偏置量b，其他部分与竞争型神经网络相同，在经过对距离n^1的竞争后，竞争胜利的神经元输出1，获得输入a^1；而其他神经元输出0，没有输出。

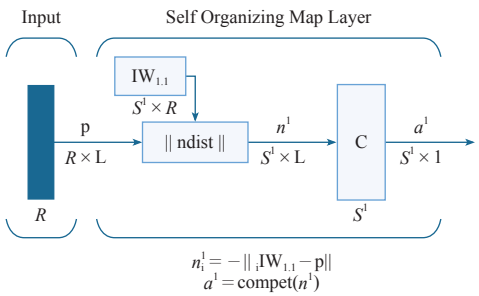

图2 SOM结构图

本文主要利用SOM进行特征层的自适应分类。

3 D－S证据理论

D－S证据理论源于20世纪60年代Dempster－Shafer在多值映射方面的工作，是用来处理不确定信息的有效方法。D－S证据理论不需要事先知道基于知识的先验概率，更具有工程实用性。

3.1 识别框架和基本概率分配函数

识别框架是证据理论的一个基本概念。它是有限个基本命题的集合，记为$\Theta=\{A_1,A_2,\cdots,A_n\}$。在故障诊断中，识别框架包括了所有可能的故障模式。由Θ的所有子集构成的集合称为幂集，记为2^Θ。

设函数m：$2^\Theta\to[0,1]$，且满足$m(\Phi)=0$，$\sum_{A\subseteq\Theta}m(A)=1$，则称$m$是$2^\Theta$上的基本概率分配函数，又称为mass函数。$m(A)$称为$A$的基本概率数，它表示依据当前环境对假设集$A$的信任程度。在故障诊断中，$m(A)$表示对故障$A$的精确信任程度，即对故障$A$的确认程度。不同的信息源得到的mass函数并不相同，这就是证据融合算法的证据组。

3.2 信度函数和似然函数

如果函数Bel：$2^\Theta\to[0,1]$，并且满足

$$\mathrm{Bel}(B)=\sum_{B\subseteq\Theta}m(B),\forall A\subseteq 2^\Theta \qquad (1)$$

则该函数称为信任函数。Bel(A)表示对A为真的信任程度，是对A信任程度的下限函数。由于，故障诊断中各证据体的焦元是单元素，所以有$\mathrm{Bel}(A)=m(A)$。

如果函数Pls：$2^\Theta\to[0,1]$，并且满足

$$\mathrm{Pls}(A)=1-\mathrm{Bel}(\bar{A}),\forall A\subseteq 2^\Theta \qquad (2)$$

则该函数称为似然函数。Pls(A)表示对A为非假的信任程度，是对A信任程度的上限函数。由此可见，事件的似然性是建立在对其相反事件不信任的基础之上的。Pls(A)计算公式也可为

$$\mathrm{Pls}(A)=\sum_{B\cap A\neq\Phi}m(B),\forall A\subseteq 2^\Theta \qquad (3)$$

3.3 证据联合规则

对同一识别框架，采用不同的信息源得出的mass函数是不同的。设m_1，m_2，…，m_n为识别框架Θ的n个mass函数，则融合后的mass函数

$m = m_1 \oplus m_2 \oplus \cdots \oplus m_n$ 可由下式计算

$$\mathrm{mass}(A) = K^{-1} \sum_{\cap A_j = A} \prod_{i=1}^{n} \mathrm{mass}_i(A_j) \qquad (4)$$

式中，$K = \sum_{\cap A_j = \Phi} \prod_{i=1}^{n} \mathrm{mass}_i(A_j)$，$j = 1,2,\cdots,m$；$K$为冲突系数，$K$反映了各mass函数之间的冲突程度，$K$越小，各mass函数之间的冲突越大；$m$为目标类型数。

4 案例验证

本文选取某无人驾驶飞机自动驾驶仪舵回路中的主通道放大电路作为案例。选取的故障器件有金属膜电阻R_1，固体钽电解电容C_1，1类瓷介电容C_2，普通双极型晶体管VD_1，按照GJB299C建立故障模式集合，共14种典型故障模式，如表1所示。选取电路输出点的电压为待观察的信号点，以此作为电路功能和状态的测试点。

表1 故障模式定义

序号	故障模式	序号	故障模式
M1	C_1－参数漂移＋5%	M8	R_1－参数漂移－5%
M2	VD_1－开路c极	M9	R_1－开路
M3	VD_1－开路b极	M10	C_1－参数漂移－5%
M4	VD_1－开路e极	M11	C_2－参数漂移＋5%
M5	VD_1－短路cb极	M12	C_2－参数漂移－5%
M6	VD_1－短路be极	M13	C_2－开路
M7	R_1－参数漂移＋5%	M14	C_2－短路

数据预处理包括故障仿真信号的归一化和拟合，对处理之后的数据提取其时间特征、频率特征和统计特征。

电路故障特征会反映在电路运行的过程参数相关特性上，包括电压值、电流值和功率值等，这些过程参数是随时间变化的，因此电路故障在时间坐标上也有所反映，即为电路故障的时间特征。

电路故障除了表现为一定的时域特征，还体现为仿真过程中的频率变化。利用傅里叶变换将时域信号转化为频域信号，从而获得其频域特征。

为了提高融合的精确性和可靠性，采用多个统计量组成统计特征。统计特性有二阶矩、四阶矩、最大绝对值以及最大幅值所对应的时刻点，预处理之后所得到的故障信号为y，采样时间间隔为Δt，计算公式为

二阶距

$$x_1 = \left(\frac{1}{m} \sum_{i=1}^{m} y_i^2 \right)^{\frac{1}{2}} \qquad (5)$$

四阶距

$$x_2 = \left(\frac{1}{m} \sum_{i=1}^{m} y_i^4 \right)^{\frac{1}{4}} \qquad (6)$$

最大绝对值

$$x_3 = \max_i |y_i| \qquad (7)$$

最大幅值点

$$x_4 = k\Delta t \quad 若 \quad y_k = \max_{i=1}^{m} y_i \qquad (8)$$

选用SOM网络作为智能分类器，进行模式分类。总共有14种故障模式的数据，经过训练建立知识库。为了保持三组特征数据统一，SOM网络具有相同的基本设置，时间特征的训练结果如图3

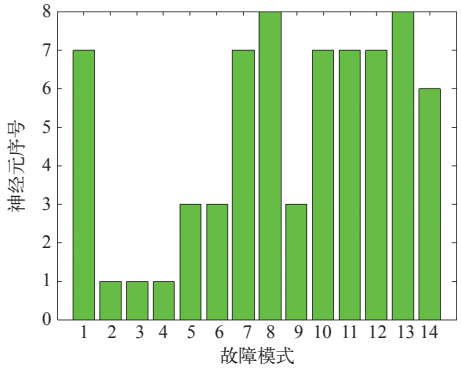

（a）时间特性分类结果

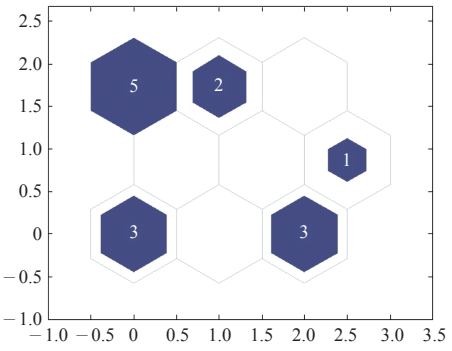

（b）神经元分类情况

图3 SOM分类结果

所示。

其中图3a横轴表示故障模式M1～M14，纵轴表示所命中的神经元序号，序号相同的模式代表被分为同一类；图3b是神经元的分类情况，从左到右，从下到上神经元的序号为1～9，与柱状图中纵轴的值对应。可以看到在3×3的网络拓扑结构中，14组输入被分为了5类，蓝色的为竞争胜利的神经元，其中的数字表示所包含的输入向量个数。频率特征和统计特征的分类结果与此相同，如表2所示。

表2 神经元分类结果

神经元分类	故障模式
F1	M1，M7，M10，M11，M12
F2	M2，M3，M4
F3	M5，M6，M9
F4	M8，M13
F5	M14

神经网络的训练并不是稳定的，当训练多次时，即使是同一组数据代入相同设置的网络，其结果也并不一定相同。这与数据自身的特性有关系，也与神经网络自身初始化函数有关。因此，在训练过程中可以适当地人为调整，以得到满意的分类结果。

本文在决策层采用D－S证据理论作为信息融合方法，主要步骤如下。

1）以特征层信息融合的输出$p(F_i)$为基础，计算故障基本概率数mT、mF和mS，作为决策层信息融合的证据组mass(F)，其中不确定性概率$m(\theta)$为SOM的误差E_n。

2）采用D－S证据联合规则进行决策层信息融合以后，得到故障的综合证据组。

3）计算故障的信度区间。由于本文故障识别框架内$\{F_1, F_2, \cdots, F_5\}$的故障假设集都是单元素集合，所以信任函数Bel($F$)＝mass($F$)，似然函数Pls($F$)＝Bel($F$)＋$m(\theta)$。

4）根据决策规则，得出故障诊断结论。

根据SOM的网络结构，提出如下基本概率分配函数

$$d_i = \sqrt{\sum_{j=1}^{N}[y(j) - P_{F_i}(j)]^2} \tag{9}$$

$$K_i = \frac{1}{d_i} \tag{10}$$

$$Nd_i = \sqrt{\sum_{j}[P_{F_0}(j) - P_{F_i}(j)]^2} \tag{11}$$

$$\mathrm{Err} = \frac{|Nd_i - d_i|}{\sum|Nd_i - d_i|} \tag{12}$$

$$E_n = \sqrt{\frac{\sum \mathrm{Err}^2}{L}} \tag{13}$$

$$m(F_i) = \frac{K_i}{\sum K_i}(1 - E_n) \tag{14}$$

$$m(\theta) = E_n \tag{15}$$

式中，d_i为期望输出y到各个神经元的欧式距离，距离越小表示匹配度越高，相应的基本概率赋值应该越大，因此对d_i取倒数得到K_i；Nd_i为实际输出$P_{F_0}(j)$到各个神经元的欧式距离；L为权值向量的长度；E_n为期望输出距离与实际输出距离之差，再进行归一化，也可以表示证据体的不确定程度。

基本概率函数就是由K_i和E_n共同计算出的。

根据训练之后的数据，按照上述公式计算出基本概率数和不确定值如表3所示。决策层信度区间如表4所示。mT为以时间特征为输入的故障模式

表3 决策层融合结果

	mT	mF	mS	mT & mF	mT & mS	mF & mS	(mT & mF) & mS
K				0.469 9	0.622 4	0.591 2	0.665 7
$m(\theta)$	0.014 4	0.148 2	0.223 6	0.004 6	0.005 2	0.056 1	0.001 5
$m(F_1)$	0.040 0	0.065 6	0.023 1	0.020 2	0.016 4	0.033 2	0.007 6
$m(F_2)$	0.023 5	0.137 5	0.014 3	0.018 5	0.009 3	0.058 9	0.006 7
$m(F_3)$	0.638 8	0.400 4	0.533 8	0.758 2	0.789 8	0.646 8	0.866 4
$m(F_4)$	0.039 6	0.062 7	0.022 9	0.019 7	0.016 2	0.031 9	0.007 4
$m(F_5)$	0.243 7	0.185 6	0.182 3	0.178 8	0.163 1	0.173 1	0.110 3

表4 决策层信度区间

	T	F	S	$T\&F$	$T\&S$	$F\&S$	$(T\&F)\&S$
$m(\theta)$	0.014 4	0.148 2	0.223 6	0.004 6	0.005 2	0.056 1	0.001 5
Pls(F_1)	0.054 4	0.213 9	0.246 7	0.024 8	0.021 6	0.089 2	0.009 2
Bel(F_1)	0.040 0	0.065 6	0.023 1	0.020 2	0.016 4	0.033 2	0.007 6
Pls(F_2)	0.037 9	0.285 7	0.237 9	0.023 1	0.014 5	0.115 0	0.008 2
Bel(F_2)	0.023 5	0.137 5	0.014 3	0.018 5	0.009 3	0.058 9	0.006 7
Pls(F_3)	0.653 3	0.548 6	0.757 4	0.762 8	0.795 0	0.702 9	0.867 9
Bel(F_3)	0.638 8	0.400 4	0.533 8	0.758 2	0.789 8	0.646 8	0.866 4
Pls(F_4)	0.054 0	0.210 9	0.246 5	0.024 3	0.021 4	0.087 9	0.009 0
Bel(F_4)	0.039 6	0.062 7	0.022 9	0.019 7	0.016 2	0.031 9	0.007 4
Pls(F_5)	0.258 1	0.333 8	0.405 9	0.183 4	0.168 3	0.229 2	0.111 8
Bel(F_5)	0.243 7	0.185 6	0.182 3	0.178 8	0.163 1	0.173 1	0.110 3

基本概率数，mF为以频率特征为输入的故障模式基本概率数，mS为以统计特征为输入的故障模式基本概率数。再以公式计算信度函数Bel(F)和似真度函数Pls(F)，如表4中1～3列所示。

采用D－S证据联合规则对mT、mF和mS两两之间进行融合，计算故障的信任函数Bel(F)和似然函数Pls(F)，经过融合以后，F_3的基本概率数分别为0.758 2，0.789 8和0.646 8，比融合前有显著提高。不确定性概率$m(\theta)$的值变为0.004 6，0.005 2和0.056 1，比融合前显著减小。实验数据表明，经过信息融合，目标故障发生的可信度提高，判断的不确定性减弱。

进一步采用D－S证据联合规则对mT、mF和mS三者之间进行融合，融合结果如表4中第7列所示。故障的信任函数Bel(F)和似然函数Pls(F)，如表4中第7列所示。

经过分析可以发现，融合以后，故障F_3的基本概率数进一步提高，变为0.866 4，满足“信任函数Bel(F)＞0.5”的决策判断规则。同时，F_3的信任函数值是所有信任函数值中的最大值，而且至少是其他故障信任函数值2倍。说明经过信息融合，“F_3发生”的可信度提高，已经达到决策规则要求。判断“F_3发生”的不确定性概率$m(\theta)$继续降低，变为0.001 5。

本文中特征层融合通过SOM网络对输入数据进行分类，并计算出分类结果的信任程度。然而，当证据体数量增多或者分类结果有冲突的时候，仅仅依靠SOM就不能得出令人信服的诊断结果。因此，在决策层进行D－S证据融合，使得对故障诊断的结果的信任程度进一步增加，减小了因为误差带来的整体不确定性，大大提高了故障诊断的准确性，是信息融合领域非常重要的手段。

5 结束语

本文将信息融合技术引入电路故障诊断领域，并提出了一种基于神经网络的基本概率分配函数，用于进行DS证据决策，通过对电路故障信号的融合处理以及对故障模式的智能识别，有效地减轻了电路故障仿真的工作量，提高了故障诊断的准确率，为信息融合技术在基于EDA的电路故障诊断与预测领域的应用开辟了新的思路。

参考文献

[1] 马平，吕锋，杜海莲，等．多传感器信息融合基本原理及应用 [J]．控制工程，2006，13 (1)：45-51．

[2] Matlab中文论坛．MATLAB神经网络30个案例分析 [M]．北京：北京航空航天大学出版社，2010．

[3] Stiller C，León F P，Kruse M．Information fusion for automotive applications－an overview [J]．Information Fusion，2011，12 (4)：244-252．

（收稿日期：2017－01－06）EA