

doi:10.11835/j.issn.1000-582X.2014.07.019

模拟电路在小波能量描述下的 Hopfield 神经网络故障诊断方法

李鹏华, 蒋建春, 邱宝梅, 梁战维
(重庆邮电大学 自动化学院, 重庆 400065)

摘要:针对模拟电路的故障诊断,提出一种采用小波包分析和能量计算作为故障特征预处理的 Hopfield 神经网络故障诊断方法。在新方法中,模拟电路在理想和实际故障情形下的输出响应分别通过 SPICE 仿真及电路终端的数据采集板所采集;故障电路输出响应通过小波包完整分解,各尺度小波系数的能量值由一个新定义的能量函数进行计算;由小波能量值所构成的理想与实测故障特征向量经能量编码后被分别作为联想记忆的记忆原型与记忆起始点,在自联想记忆驱动下,实测模拟电路故障的编码被 Hopfield 神经网络准确分类。数值实验结果表明新方法对具有微弱幅值响应的硬故障与具有较大幅值响应的软故障采取的故障特征预处理效果较好,新定义的能量函数与编码规则对模拟电路的故障诊断准确性影响显著。

关键词:故障诊断;模拟电路;小波包分析;能量计算;Hopfield 神经网络

中图分类号:TP277

文献标志码:A

文章编号:1000-582X(2014)07-136-11

A fault diagnosis method of analog circuit using energy calculation and Hopfield neural network

LI Penghua, JIANG Jianchun, QIU Baomei, LIANG Zhanwei

(College of Automation, Chongqing University of Posts and Telecommunications,
Chongqing 400065, China)

Abstract: A new Hopfield neural network fault diagnosis method using the wavelet packet analysis and energy calculation as fault feature preprocessing is presented for the analog circuit. In the proposed method, the ideal and actual responses of the fault analog circuit are sampled by SPICE simulation and a data board in the terminal of the circuit, respectively. The sampled responses are completely decomposed by the wavelet packet analysis, the energy values of wavelet coefficients in each level are calculated by a new defined energy function. The ideal and the actual fault vectors, being composed of the energy values, are used as the memory prototypes and the initial states after the energy encoding. The energy codes of the actual fault responses are accurately classified by the Hopfield neural network. The numerical experiments clearly demonstrate that the effects of the new fault feature extraction for the hard fault responses with weak amplitudes are the same efficacious as the soft fault responses with large amplitudes, the new defined energy function and the encoding rules have significant impact on analog fault circuit.

Key words: fault diagnosis; analog circuit; wavelet packet analysis; energy calculation; hopfield neural network

收稿日期:2014-04-03

基金项目:重庆市科技创新人才培养项目(cstc2013kjrc-qnrc40005);重庆邮电大学引进人才启动基金(A2013-07);重庆市教委科学技术研究项目(KJ1400404, KJ110521)

作者简介:李鹏华(1984-),男,重庆大学博士,主要从事故障诊断,量子神经网络的研究,(E-mail)lipenghua88@163.com。

系统与外界的信息交互,很大程度依赖于模电信号的采集、传输、滤波、放大、转换等过程。作为这些过程的实施主体,模拟电路是许多复杂系统的基本构件,其可靠性直接影响着系统能否稳定、安全的运行。因此,对模拟电路进行的故障诊断一直是电子工业的研究重点。

鉴于故障模型匮乏、电路元件非线性等因素的影响,模拟电路被视为最不稳定的可测系统^[1-3],其故障诊断依然存在诸多难题。例如外界噪声的随机干扰、无故障元件偏离其容限允许程度的未知性以及软故障的不确定性等问题,给准确地诊断模拟电路故障带来很大困难。

经过十多年的发展,国内外众多专家学者针对芯片级、板级、系统级的模拟电路,开展了大量富有成效的研究^[4-13]。其中的大部分研究聚焦于利用小波分析作等信号处理技术进行故障特征提取,并通过神经网络等智能方法进行故障分类器设计。文献[3,5-7]将模拟电路输出响应直接作为神经网络的输入,使得网络结构复杂,训练时间过长,诊断准确率较低。文献[8]依据模拟电路不同的故障类型,将其划分为不同的子模块,每个子模块采用相同类型的神经网络实现故障诊断,并使用主元分析减少各个神经网络的输入维数,在降低网络复杂性的同时,也使诊断准确率有所提高。在文献[2,6]中,作者从故障电路响应中抽取低频小波系数作为故障特征,在采用主元分析降维后提交给神经网络,使网络的复杂性在一定程度上有所降低。文献[13]将小波系数的能量值作为故障特征,极大降低神经网络的复杂性,但能量数值很小,造成故障特征的类间距离较小,类内距离较大,故障分类效果并不理想。而文献[12]的诊断结果虽然很好,但未给出具体的能量算式。此外,综观上述诊断方法,依然有以下值得探讨的问题:

1)上述方法在采用小波系数(或能量值)作为故障特征时,考虑到随后故障分类中神经网络的复杂性,通常舍弃故障响应的细节信息而选取表征其基本结构的近似小波系数(或能量值)作为故障特征。从信息完整的角度来看,遗弃的高频系数对特征信息的完整表达是有价值的,因而在故障特征提取过程中有必要将其考虑在内。

2)上述方法通常采用诸如 BP、RBF 等前馈网络作为故障分类器。这些网络并不具备动态特性,仅完成从输入空间到输出空间的固定权值映射,在一定程度上使网络对个别器件的软故障不灵敏,造成故障漏报。而动态递归网络依据统计力学原理,通过反馈方法在非线性的单元中对网络初始态和终态进行一系列处理,使网络在权值调整过程中,除显示稳定状态外,还产生并存储时空模式,因而在模式识别的故障分类中能取得良好效果。

针对上述问题,提出一种采用小波包分解和 Hopfield 网络分别作为故障特征提取和故障分类器的模拟电路故障诊断方法。该方法通过数据采集板与 SPICE 仿真分别获得模拟电路的实际输出响应和理想输出响应,将两类信号在小波包机制下完整分解。为使故障特征具有良好可分性,定义一种新的能量函数来计算各小波系数的能量值,并将这些能量值合并成向量以作为故障特征。在完成对各故障特征向量的能量编码后,将故障编码提交给 Hopfield 网络以实现准确的故障分类。以线性电路和非线性电路的软、硬故障为例的数值实验表明:模拟电路的故障响应与正常响应特征之间,以及各故障响应特征之间可分性良好,特征向量充分涵盖了各类故障本质信息;对各故障特征的 Hopfield 编码使得通过 Hopfield 网络所进行的故障诊断,具有快速、准确的效果。

1 故障诊断方法

基于小波包分析和 Hopfield 网络的模拟电路故障诊断方法如图 1 所示。该方法的体系结构分为数据获取、特征提取与故障分类 3 部分。

在数据获取模块中,模拟电路的输出响应分别通过 SPICE 仿真与连接在实际电路终端的数据采集板进行数据采样,以获得理想输出响应数据集和实测输出响应数据集;在特征提取模块中,理想与实测的电路输出响应分别作为训练与测试数据集进行小波包分解,在进行能量计算获得的能量值的基础上,将这些能量值构成相应故障的特征向量;在故障分类模块中,各样本的特征向量经过 Hopfield 编码后提交给 Hopfield 网络以实现准确、迅速的故障分类。

1.1 能量计算与能量编码

作为小波分析的延伸,小波包分析^[14-15]通过尺度变换,将电路输出响应分解为以近似系数表征的低频成分和以细节系数表征的高频成分。小波变换可描述为母小波的尺度变换与平移变换,即

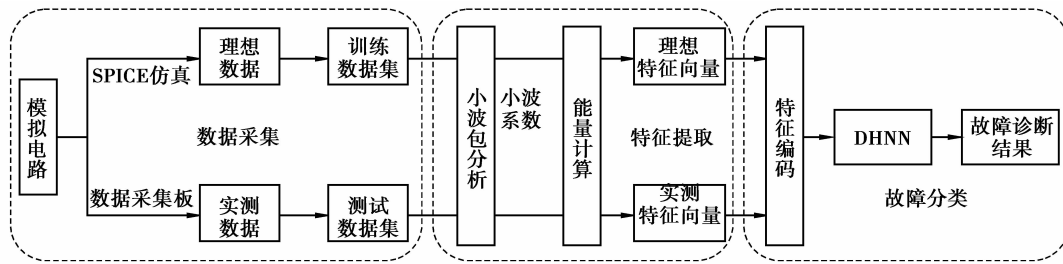


图 1 故障诊断方法的体系结构

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right), \quad (1)$$

这里: $\psi_{a,b}(x)$ 表示母小波函数; a 与 b 分别代表变换的尺度和平移因子。电路响应 $I(x)$ 的对应小波系数可表示为

$$C(a,b) = \langle \psi_{a,b}(x), I(x) \rangle = \frac{1}{\sqrt{a}} \int I(x) \psi\left(\frac{x-b}{a}\right) dx, \quad (2)$$

在实际的工程应用中,通常使用离散二进制小波变换,以实现计算机中的高效运算。为此,需将式(2)中的尺度因子与平移因子分别设置为 $a=2^j$ 和 $b=k2^j$ 。根据多分辨思想,电路响应 $I(x)$ 在各个尺度上被小波包分解为低频的近似系数和高频的细节系数。

通过分析电路响应的小波系数,可获得统计直方图、均方差、协方差矩阵、能量值等统计信息^[16],用以描述故障特征。其中,通过对小波系数实施能量计算所获得的能量值是一种高效的故障特征描述方式。借助小波能量值,可在能量空间中对具有不同频率的故障特征进行更加细致的区分。在利用离散小波变换分析时间序列的报告中,Morchen^[17]将小波系数的能量值定义为

$$E_{m,n}(x) = \sum_{i=1}^N |C_i^{m,n}(x)|^2 = \|C_i^{m,n}(x)\|_2^2, \quad (3)$$

此处, m 为小波分解的尺度, n 为在尺度 m 下的小波树节点个数,在小波节点 (m,n) 处的小波系数长度用 N 表示。Ekici 等^[20]对式(3)的定义进行了推广

$$E_{m,n}(x) = \sum_{i=1}^N |C_i^{m,n}(x)|^p = \|C_i^{m,n}(x)\|_p^p, \quad (4)$$

其中, $1 \leq p \leq \infty$ 。实际上,上述研究^[12-13,16,18-19]大多采用式(3)进行能量计算。然而,采用该定义得到的能量特征可分性较差,使得同一类别的能量特征相距较远,不同类别的能量特征相距较近。虽然式(4)表示的能量可通过改变 p 值提高特征的可分性,但 p 值的确定在很大程度上取决于研究者的经验,且当故障对象改变时,当前的 p 值也需随之更改,通用性较差。为此,给出一种新的小波系数能量定义

$$E_{m,n}(x) = \|C^{m,n}(x)\|_2^2 N^{-1} \sum_{i=1}^N \exp\left(-\frac{C_i^{m,n}(x)^2}{2}\right), \quad (5)$$

通过式(5)计算得到的各小波系数能量值组合在一起便构成相应的电路响应特征向量。为提高诊断的快速性,这些特征向量还需按照如图 2 所示的规则进行能量编码。

在图 2 中,向量 $A \in \mathbf{R}^{m \times 1}$ 由特定实测故障响应的能量值构成,矩阵 $B \in \mathbf{R}^{m \times n}$ 由所有理想故障响应的能量值构成(n 表示已知的故障种类数, m 表示在特定故障下,相应电路响应的所有小波系数能量值拼接构成的向量维数), $C \in \mathbf{R}^{m \times n}$ 表示最终获得的实测故障所对应的编码矩阵。该编码过程是一个全局搜索的过程,准确地刻画了不同故障特征能量值所对应的编码状态。

1.2 离散 Hopfield 神经网络

Hopfield 神经网络是一种异步非线性动态系统,系统的相空间由表示网络原型状态的稳定点(吸引子)构成,通过系统局部单元之间的相互作用,网络的整体动态特性得以体现(集体涌现)^[21]。在网络运作过程中,提交给网络的响应为相空间的起始点,若起始点“接近”记忆检索的稳定点,则动态系统将随时间演化到该记忆状态,即系统状态的相空间流转换到该记忆状态。因此,Hopfield 网络可执行在动态稳定环境中模式

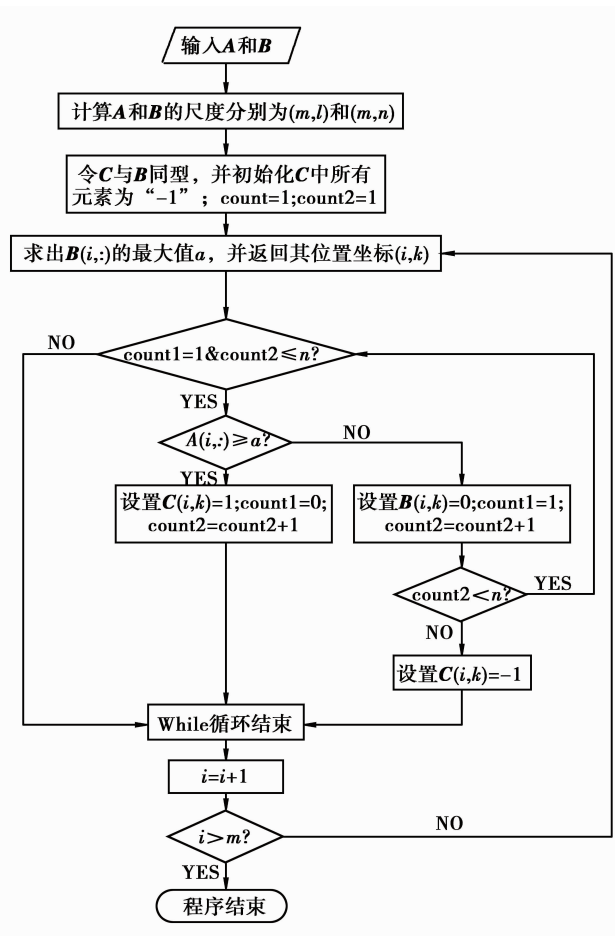


图 2 小波系数能量编码过程

识别的功能^[22-23]。图 3 给出典型的离散 Hopfield 神经网络结构,其神经元在架构上采用 McCulloch-Pitts 模型^[24],激活函数为硬限幅函数,任意时刻的神经元状态只能是“+1”或“-1”。

对于图 3 中的每一神经元,线性组合器的输出可表示为

$$v_i(k) = \sum_{j=1}^n w_{ij} x_j(k) - \theta_i(k) = \mathbf{w}_i^T \mathbf{x}(k) - \theta_i(k), \quad (6)$$

其中: $\mathbf{x}(k) = [x_1(k), x_2(k), \dots, x_n(k)]^T$ 是网络的状态(提交给网络的故障特征编码); $\theta_i(k)$ 是外部应用阈值。对于 $i=1, 2, \dots, n$, 每一线性组合器输出传给对称硬限幅激活函数与单元延迟单元。任意神经元的单元延迟输出 $x_j(k)$ 作为反馈给其他神经元的输入,但并不反馈给自己。也就是当 $i=j$ 时, $w_{ij}=0$, 而其他神经元的状态可表示为

$$x_i(k+1) = \text{sgn}(v_i(k)) = \begin{cases} +1 & v_i(k) > 0 \\ -1 & v_i(k) < 0 \end{cases}, \quad (7)$$

因此,网络输出的矢量形式为

$$\mathbf{x}(k+1) = \text{sgn}(W\mathbf{x}(k) - \theta(k)), \quad (8)$$

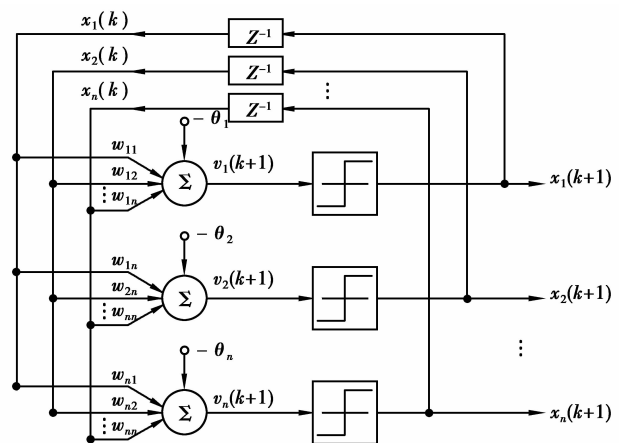


图 3 离散 Hopfield 神经网络

此处, $\boldsymbol{\theta}(k) = [\theta_1(k), \theta_2(k), \dots, \theta_n(k)]^T$, $\mathbf{W} \in \mathbf{R}^{n \times n}$ 。在存储阶段, 网络的联想记忆由相关矩阵记忆的外积规则建立。假定 r 个原型记忆的集合 $\{\varphi_1, \varphi_2, \dots, \varphi_r\}$, 则网络权值可由下式计算

$$\mathbf{W} = \frac{1}{n} \sum_{i=1}^r \varphi_i \varphi_i^T - \frac{r}{n} \mathbf{I}, \quad (9)$$

其中, \mathbf{I} 为同型的单位矩阵。在回忆阶段, 提交测试输入向量 $\mathbf{x}' \in \mathbf{R}^{n \times 1}$ 给网络, 初始化具有未知输入值的网络状态 $\mathbf{x}(k)|_{k=0} = \mathbf{x}(0) = \mathbf{x}'$ 。运用式(8), 状态向量 $\mathbf{x}(k)$ 异步更新, 直到向量元素没有变化为止。此时, 稳定状态 x_e 就是网络输出。

2 案例电路与方法应用

本节以 Sallen-Key 带通滤波器和非线性整流电路为例, 应用提出的方法进行故障诊断。其中, 前者主要考察软故障模式, 后者主要考察硬故障模式。

2.1 故障电路

案例 1 故障电路如图 4 所示, 为一个中心频率在 25 kHz 的 Sallen-Key 带通滤波器。假定该电路中各个电容与电阻的容限分别为 10% 和 5%。若 R_2, R_3, C_1, C_2 中的任一器件低于/高于其正常值的 50%, 而其他电阻和电容都在其允许的容限范围内工作, 则 Sallen-Key 滤波器输出相应的 8 种故障响应: $R_2 \downarrow, R_3 \downarrow, C_1 \downarrow, C_2 \downarrow, R_2 \uparrow, R_3 \uparrow, C_1 \uparrow, C_2 \uparrow$ 之一。这里, \downarrow 和 \uparrow 分别表示低于正常值的 50% 与高于正常值的 50%。

案例 2 故障电路如图 5 所示, 为一个将 AC 电源转化为 DC 电源的非线性整流电路。若电路中 D_1, C_1, C_2, C_3 任一器件断路/短路, 且其他器件正常工作, 则该电路输出相应 8 种硬故障: $D_1^\circ, D_1 \cdot, C_1^\circ, C_1 \cdot, C_2^\circ, C_2 \cdot, C_3^\circ, C_3 \cdot$ 之一。这里, 符号 $^\circ$ 和 \cdot 分别表示相关器件处于断路和短路状态。

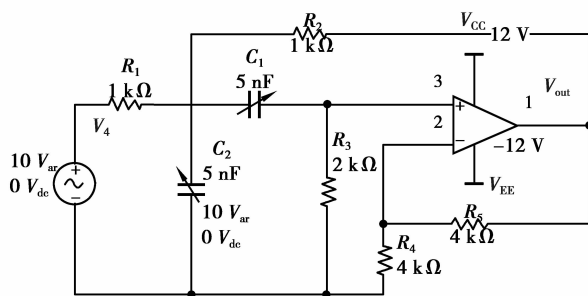


图 4 Sallen-Key 带通滤波器




图 5 非线性整流电路


2.2 数据采集

针对 Sallen-Key 滤波器和非线性整流电路, 分别施加脉冲激励(周期 10 μ s, 幅值 5 V)和正弦波激励(频率, 幅值 10 V)。在不同故障模式下, 2 种电路的理想输出响应由 SPICE 仿真得到, 实际输出响应通过位于电路终端的数据采集卡采样获取。数据采集卡的采样率为 500 Ks/s, 采样时间为 10 ms。


2 种电路在不同故障模式下的理想与实测输出响应由图 6 给出(NF 表示正常的输出响应)。从图 6(a)和(a)式(3)定义下的实测响应能量分布(b)式(5)定义下的理想响应能量分布(c)式(5)定义下的实测响应能量分布(a)式(3)定义下的实测响应能量分布(b)式(5)定义下的理想响应能量分布(c)式(5)定义下的实测响应能量分布(b)可明显看出, 在软故障情形下, 正常输出响应与故障输出响应之间差异并不明显, 需采用有效方法提取出相关的故障特征以实现准确的故障诊断。

2.3 特征提取


在得到上述电路的输出响应后, 采用 Haar 小波基对其进行层数为 3 的小波包分解。籍此得到的高频和低频小波系数, 并按照式(5)给出的定义进行能量计算。需要说明的是, 为验证新能量定义的有效性, 上述小波系数根据式(3)同样也进行了能量计算, 以此获得相应的对比结果。图 7 和图 8 分别给出由此得到的 Sallen-Key 带通滤波器和非线性整流电路的能量值分布。其中, 图 7(a)~(c)中的 F_1, \dots, F_8 分别表示 $C_1 \downarrow, C_2 \downarrow, R_2 \downarrow, R_3 \downarrow, C_1 \uparrow, C_2 \uparrow, R_2 \uparrow, R_3 \uparrow$; 图 8(a)~(c)中的 F_1, \dots, F_8 分别表示 $C_1 \cdot, C_2 \cdot, C_3 \cdot, D_1 \cdot, C_1^\circ, C_2^\circ, C_3^\circ, D_1^\circ$; NF 均表示无故障。图 7(a)所示的能量特征子空间中, 能量值集中分布在小波树节点(3,0)处, 而其他位置



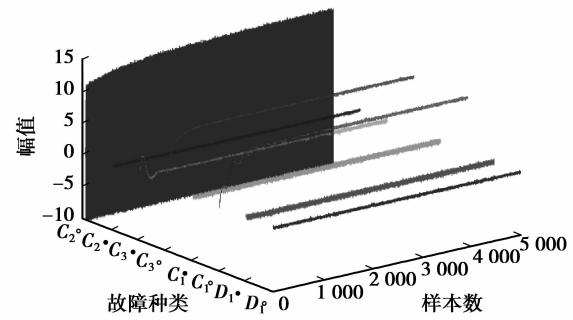
(a) Sallen-Key带通滤波器的SPICE仿真输出响应



(b) Sallen-Key带通滤波器的实测输出响应



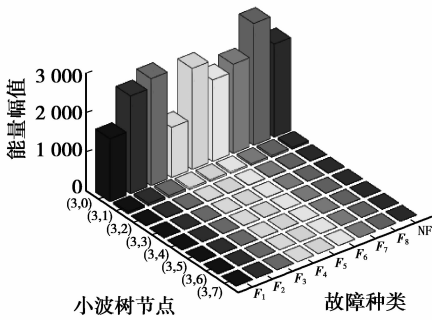
(c) 非线性整流电路的SPICE仿真输出响应



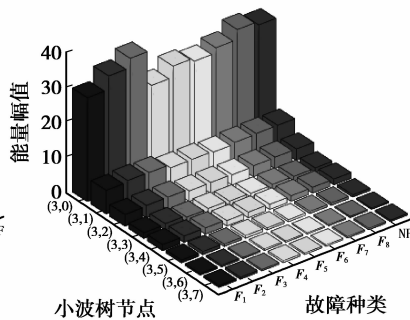
(d) 非线性整流电路的实测输出响应

图 6 两种电路的输出响应

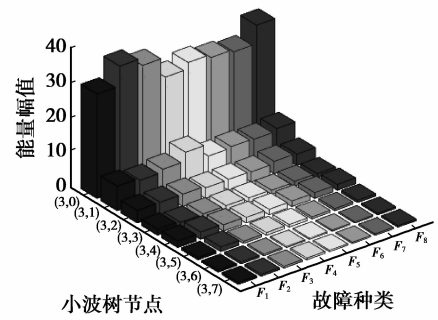
的能量幅值都很小,且彼此相对差值较小,不易区分。类似地,在图 8(a)所示的能量特征子空间中,除第 6 种故障在各个尺度的能量特征存在较为明显的差别外,其他故障的能量值分布均无明显差别。



(a) 式(3)定义下的实测响应能量分布




(b) 式(5)定义下的理想响应能量分布




(c) 式(5)定义下的实测响应能量分布


图 7 Sallen-Key 带通滤波器的故障能量特征分布



(a) 式(3)定义下的实测响应能量分布



(b) 式(5)定义下的理想响应能量分布



(c) 式(5)定义下的实测响应能量分布

图 8 非线性整流电路的故障能量特征分布

众所周知,不同故障之间或故障与正常状态之间的特征数值差别越大,不同故障之间或故障与正常状态之间的模式分类就越明显,这样的故障特征就越有利于故障诊断。从这一点来说,式(3)描述的能量计算在故障特征提取的过程中是失效的。相反,按提出的能量算子而得到的能量特征,在各个小波树节点的能量值区分较为明显。此外,该能量算子的性能也较为稳定,图 7(a)和图 8(a)中能量值的数量级分别为 10^3 和 10^5 ,而图 7(b)~(c)和图 8(b)~(c)中能量值的数量级均为 10^1 。

2.4 故障分类

由于离散 Hopfield 神经网络中神经元的状态只能为“ -1 ”或“ $+1$ ”,要实现快速准确地故障诊断,还需要对故障特征空间中的各元素进行编码,此过程可理解为在“编码准则”下的数据“归一化”。图 9 和图 10 分别给出 Sallen-Key 滤波器和非线性整流电路在 1.1 节描述的编码准则下的实测故障特征编码。图中红色菱形部分表示“ $+1$ ”,其余蓝色部分表示“ -1 ”。值得指出的是,图 9 中 F_1, \dots, F_8 分别表示 $C_1 \downarrow, C_2 \downarrow, R_2 \downarrow, R_3 \downarrow, C_1 \uparrow, C_2 \uparrow, R_2 \uparrow, R_3 \uparrow$;图 10 中的 F_1, \dots, F_8 分别表示 $C_1 \cdot, C_2 \cdot, C_3 \cdot, D_1 \cdot, C_1^\circ, C_2^\circ, C_3^\circ, D_1^\circ$; (3,7) 分别表示相应小波节点的状态。




图 9 Sallen-Key 带通滤波器的实测故障特征编码

图 9 和图 10 中所示的实测故障特征编码被当作“记忆初始点”(网络输入)提交给 Hopfield 神经网络,而 2 种电路在 SPICE 仿真下(理想情形)的故障特征编码则被当作“记忆稳态”(网络目标向量)提交给 Hopfield 网络。

在设定好合适的时间步长后故障空间中的实测故障特征编码在 Hopfield 网络自联想记忆驱动下,朝预定的记忆稳态(故障记忆原型)演化,最终使得网络输出为记忆原型中的某个稳定状态,进而实现快速准确的故障分类。具有软故障的 Sallen-Key 滤波器和具有硬故障的非线性整流电路,通过应用本文所提方法所得到的诊断结果分别显示在图 11 和图 12 中。需要说明的是,在图 11 所示的诊断结果中, F_1, \dots, F_8 分别表示 $C_1 \downarrow, C_2 \downarrow, R_2 \downarrow, R_3 \downarrow, C_1 \uparrow, C_2 \uparrow, R_2 \uparrow, R_3 \uparrow$ 。当待诊断的 Sallen-Key 带通滤波器发生其中某种故障时, F_1, \dots, F_8 所对应的列元素被激活,并被设置为“ $+1$ ”,由图 11 中的绿色方块表示;而未被激活的其余元素依然保持为“ -1 ”,由图 11 中的红色方块表示。类似地,图 12 中的 F_1, \dots, F_8 分别表示 $C_1 \cdot, C_2 \cdot, C_3 \cdot, D_1 \cdot, C_1^\circ, C_2^\circ, C_3^\circ, D_1^\circ$ 8 种故障。当非线性电路发生其中的某种故障时,在图 12 中相应的故障位置

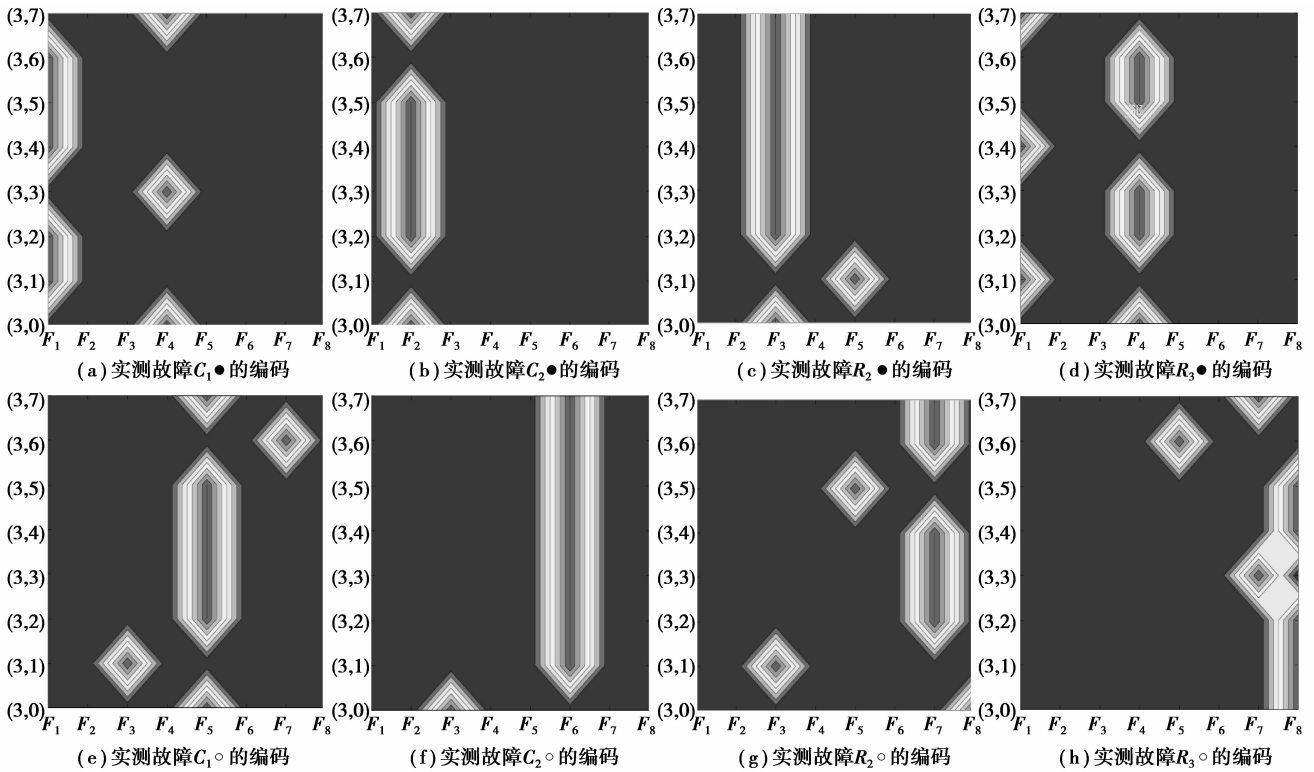


图 10 非线性整流电路的实测故障特征编码

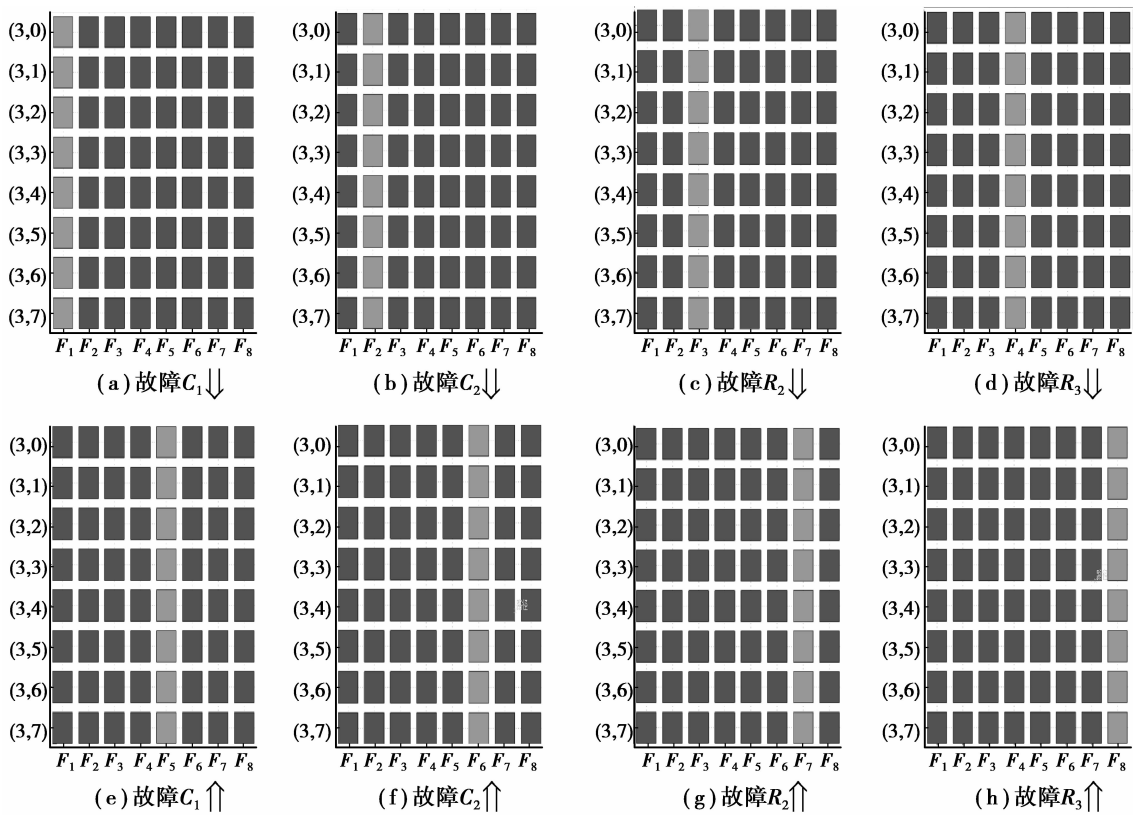


图 11 Sallen-Key 带通滤波器的故障诊断结果

上,处于小波树节点(3,0),⋯,(3,7)的能量值被激活为“+1”,其余未发生的故障位置处的能量值被设置为“-1”。

从图 11 和图 12 可清晰地看出,Sallen-Key 带通滤波器软故障的诊断结果和非线性电路硬故障的诊断

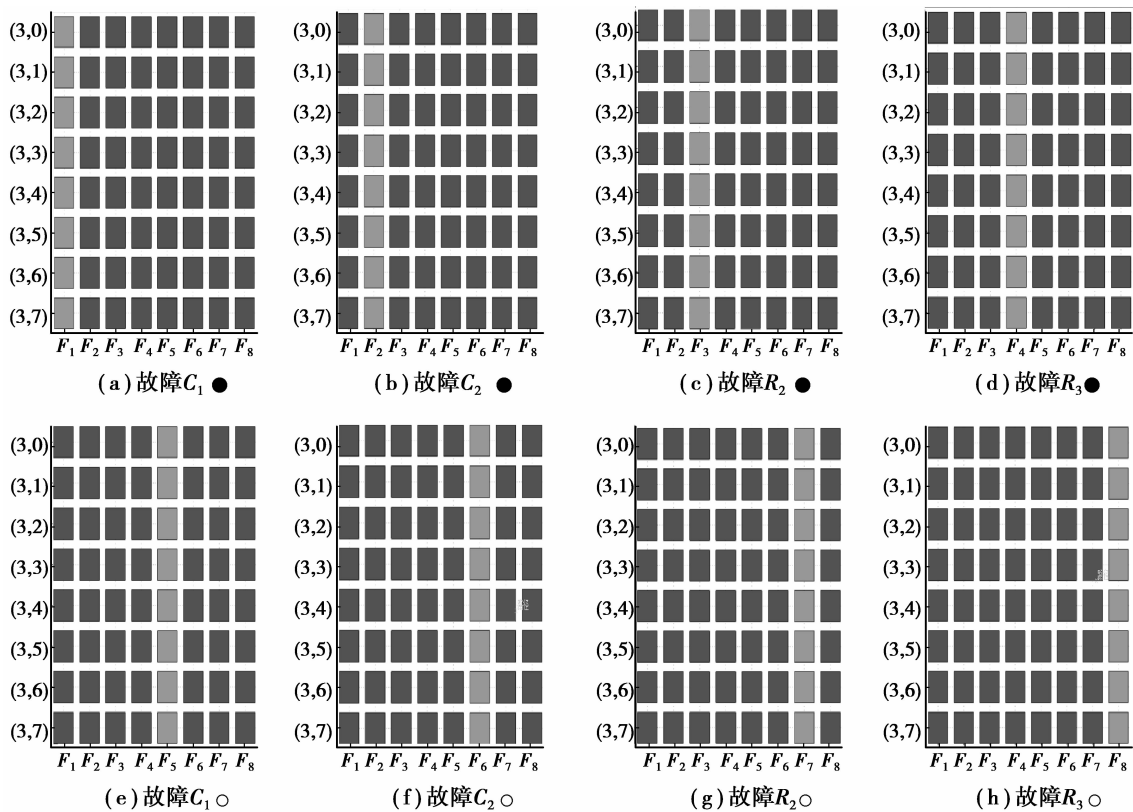


图 12 非线性整流电路的故障诊断结果

结果与其各自提交给 Hopfield 神经网络的故障编码类型是一致的。也就是说,2 种电路的不同故障能量特征在 Hopfield 神经网络中得到了准确的分类。

3 结果分析

事实上,故障特征提取的有效性对于故障诊断结果的准确性有着重要影响。当不同种类故障的特征数值之间差异较大,并且这些故障的特征数值与正常状态的特征数值之间也存在较大差异时,所提取到的故障特征对于准确地实现故障诊断就越有利。就故障特征提取而言,图 7 和图 8 所示的能量特征分布清晰地显示出,能量函数能较好地刻画两种电路的软/硬故障特征。

对于故障分类,通过将上述两种电路的理想故障特征和实测故障特征分别定义为联想记忆中的记忆原型与记忆的起始点。在 Hopfield 神经网络的驱动下,这些起始点随时间收敛到记忆原型,从而实现故障分类。此外,由于 Hopfield 神经网络并不需要训练,只要确定网络的记忆原型(稳定点)便可实现故障诊断。从这一点来说,在同样的能量特征描述下,采用 Hopfield 神经网络的故障诊断方法在时间花销上远远低于采用前馈类型的神经网络。更为重要的是,Hopfield 神经网络中记忆原型的确定,仅需根据故障能量特征维数设置为“+1”或“-1”,相比于前馈神经网络选择合适的目标函数更为方便。从这一点来说,Hopfield 神经网络无需考虑网络输入的复杂性。而在采用前馈神经网络的故障诊断中,当输入数据维数过高,为降低网络的复杂性,必须考虑采用诸如 PCA 这类方法进行降维。

从实际的 2 种电路的故障诊断结果来看,对于 Sallen-Key 滤波器的软故障和非线性整流电路的硬故障,故障诊断的准确率都达到 100%,为进一步说明方法的有效性,对上述 2 种电路按文献[2]、文献[3]、文献[12]、文献[13]所提方法进行了故障诊断。相关的故障诊断结果由表 1 给出。

表1 研究与其他文献电路故障诊断结果比较

故障电路	故障诊断的准确率			研究
	文献[3]	文献[2]	文献[13]	
Sallen-Key 滤波/%	88.89	100	88.89	100
非线性整流电/%	55.56	88.89	22.22	100

4 结 论

将小波包分析和 Hopfield 神经网络应用于模拟电路的故障诊断之中,并通过定义新的能量函数及其能量编码规则,有效提高故障诊断的准确性。在所提诊断方法中,通过 SPICE 仿真和电路终端的数据采集板分别获取理想和实际情形的故障响应;通过 3 层的小波包分解提取故障响应的完整小波系数,并利用新定义的能量函数计算各小波系数的能量值,以构成故障输出响应的故障特征向量;在对故障能量特征实施能量编码后,理想和实测的故障编码分别作为记忆原型和记忆起始点提交给 Hopfield 神经网络;最终借助自联想记忆快速准确地诊断出故障。在具有软故障的 Sallen-Key 滤波器和具有硬故障的非线性整流电路的实际案例分析中,新定义的能量函数合理有效,对软故障和具有微弱信号的硬故障模式所提取的特征区别明显,以 Hopfield 神经网络为诊断器所进行的故障诊断具有较高的准确率。

参考文献:

- [1] Lifan Y, Yigang H, Jiaoying H, Yichuang S. A new neural network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor[J]. IEEE Trans. Instrum. Meas., 2010, 59(3): 586-595.
- [2] Farzan A, Mehran minian A, Collins H W. Analog fault diagnosis of actual circuits using neural networks[J]. IEEE Trans. Instrum. Meas., 2002, 51(3): 544-550.
- [3] Catelani M, Fort A. Soft fault detection and isolation in analog circuits; some results and a comparison between a fuzzy approach and radial basis function networks[J]. IEEE Trans. Instrum. Meas., 2002, 51(2): 196-202.
- [4] Spina R, Upadhyaya S. Linear circuit fault diagnosis using neuromorphic analyzer[J]. IEEE Trans. Circuits Syst. II, 1997, 44(3): 188-196.
- [5] Maidon Y, Jervis B W, Fouillat P S. Using artificial neural networks or lag range interpolation to characterize the faults in an analog circuit; an experimental study[J]. IEEE Trans. Instrum. Meas., 1999, 48(5): 932-938.
- [6] Aminian M, Aminian F. Neural network based analog circuit fault diagnosis using wavelet transform as preprocessor[J]. IEEE Trans. Circuits Syst. II, Analog Digit. Signal Process, 2000, 47(2): 151-156.
- [7] Negnevitsky M, Pavlovsky V. Neural networks approach to online identification of multiple failures of protection systems[J]. IEEE Trans. Power Delivery, 2005, 20(2): 588-594.
- [8] Mehran A, Farzan A. A modular fault-diagnostic system for analog electronic circuits using neural networks with wavelet transform as a preprocessor[J]. IEEE Trans. Instrum. Meas., 2007, 5(5): 1546-1554.
- [9] Tan Y, He Y, Cui C, Qiu G. A novel method for analog fault diagnosis based on neural networks and genetic algorithms[J]. IEEE Trans. Instrum. Meas., 2008, 57(11): 2631-2639.
- [10] 王新攀, 王红, 杨士元. 基于非正弦激励的模拟电路故障诊断[J]. 清华大学学报, 2011, 51(S1): 149-1498.
WANG Xinpan, WANG Hong, YANG Shiyuan. Non-sinusoidal stimulus based analog-circuit fault diagnostics[J]. Journal of Tsinghua University, 2011, 51(S1): 1494-1498.
- [11] 邓勇, 师奕兵. 基于相关分析的非线性模拟电路参数型故障诊断方法[J]. 控制与决策, 2011, 26(9): 1407-1411.
DENG Yong, SHI Yibin. Approach of parametric fault diagnosis in nonlinear analog circuits based on correlation analysis[J]. Control and Decision, 2011, 26(9): 1407-1411.
- [12] 祝文姬, 何怡刚. 一种新的模拟电路故障特征提取与诊断方法[J]. 湖南大学学报, 38(4): 41-46.
ZHU Wenji, HE Yigang. A new fault feature extraction and diagnosis method of analog circuits[J]. Journal of Hunan University, 2010, 38(4): 41-46.
- [13] 王军锋, 张维强, 宋国乡. 模拟电路故障诊断的多小波神经网络算法[J]. 电工技术学报, 2006, 21(1): 33-36.

- WANG Junfeng, ZHANG Weiqing, SONG Guoxiang. Fault diagnosis algorithm of analog circuit based on multi wavelet neural network[J]. Transactions of China Electro Technical Society, 2006, 21(1): 33-36.
- [14] Shensa M J. The discrete wavelet transform: wedding the atrous and mallat algorithms[J]. IEEE Trans. Sig. Proc., 1992, 40(10): 2464-2482.
- [15] Lang M, Guo H, Odegard J E, Burrus C S. Noise reduction using an undecimated discrete wavelet transform[J]. IEEE Trans. Sig. Proc., 1996, 3(1): 10-12.
- [16] Chacko B P, Vimal Krishnan V R, Raju G, Babu Anto P. Handwritten character recognition using wavelet energy and extreme learning machine[J]. Int. J. Mach. Learn. & Cyber., 2012, 3: 149-161.
- [17] Morchen F. Time series feature extraction for data mining using DWT and DFT[R]. Technical Report, No.33, Department of Mathematics and Computer Science, University of Marburg, Germany, 2003.
- [18] Hu G S, Zhu F F, Ren Z. Power quality disturbance identification using wavelet packet energy entropy and weighted support vector machines[J]. Expert Systems with Applications, 2008, 35: 143-144.
- [19] Wu X Q, Wang K Q, Zhang D. Wavelet energy feature extraction and mathing for palmprint recognition[J]. Comput. Sci. & Technol., 2005, 20(3): 411-418.
- [20] Ekici S, Yildirim S, Poyraz M. Energy and entropy-based feature extraction for locating fault on transmission lines by using neural network and wavelet packet decomposition [J]. Expert Systems with Applications, 2008, 34: 2937-2944.
- [21] Hopfield J J. neural networks and physical systems with emergent collective computational ability[C]. Proceeding of the national academy of science, USA, 1982, 79: 2554-2558.
- [22] Zheng P, Zhang J, Tang W. Learning associative memories by error backpropagation[J]. IEEE Trans. Neural Netw., 2011, 22(3): 347-354.
- [23] Davey N, Hunt S P, Adams R G. High capacity recurrent associative memories[J]. Neurocomputing, 2004, 62: 459-491.
- [24] McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity[J]. Bulletin of Mathematical Biophysics, 1943, 5(11): 115-133.

(编辑 侯 湘)