

利用可拓類神經網路第一型應用於電子電路故障診斷

Application of Extension Neural Network to Fault Diagnosis of Electronic Circuit

黎修宏
勤益科技大學
電機工程系

man970@hotmail.com

王孟輝
勤益科技大學
電機工程系

wangmh@ncut.edu.tw

鍾裕國
勤益科技大學
電機工程系

s49712103@ncut.edu.tw

葉郁祺
勤益科技大學
電機工程系

kiki0118@ncut.edu.tw

摘要

由於電路中元件的數值普遍存有誤差量，且因現在的電路越來越精密，元件值之誤差造成交互作用，使電子電路之故障診斷越來越困難。因此，本文提出以可拓類神經網路第一型(Extension Neural Network Type-1, 簡稱ENN-1)應用於電路故障診斷，本方法結合了可拓理論和類神經網路，利用可拓類神經網路建立出故障各類型的物元模型(matter-element model)，並以關聯函數計算特徵和故障種類之關聯度，經由關聯度之分析可直接診斷故障原因。本文所提之方法也與傳統多層神經網路(MNN)和 k-mean 等方法做比較，在實測模擬結果中證實本方法之辨識率及容錯能力較高。

關鍵字：可拓類神經第一型(ENN-1)、可拓理論、類神經、物元模型。

Abstract

The values of electronic components are always deviation, but the functions of the modern circuits were more and more precise, which causes the automatic fault diagnosis of analog circuits very complex and difficult. This paper presented an extension neural network type - 1 (ENN-1) based method for fault diagnosis of analog circuits. This proposed method combines the extension theory and neural networks to create a novel neural network. Using the matter-element models of fault types and a correlation function can be to calculate the correlation degree between the tested pattern and every fault types, then the cause of the circuit's malfunction can be directly diagnosed by the analysis of the correlation degree. The experimental results show that the proposed method has a high diagnostic accuracy, and more fault-tolerant than the multilayer neural network (MNN) based methods and the k-means based method.

Keywords : ENN-1, Extension theory, Neural network, Matter-element model.

1. 前言

在實際的情況中，電子零件的元件值都會存在著一定的誤差，例如：電阻的最後一個色環就是用來標示誤差的範圍，所以每個元件出廠時都存有誤差，因此會造成電路特性的偏移，但只要還在容許誤差範圍內，同時電路輸出結果是符合要求的，則電路還算是正常情況，但是當元件值超過誤差範圍時就會產生故障。因此電路故障可分為：硬性故障(hard faults)和軟性故障(soft faults) [1]。一般來說電路如果發生燒毀或不能動作時，此類故障稱為硬性故障，而軟性故障是指元件值超過容許的範圍所引起的故障，但是電路依然能運作，只是輸出結果是屬於錯誤的，同時也會破壞到電路輸出之特性，因此軟性故障相較於硬性故障會更難偵測到[2-3]。普遍元件值介於 $\pm 5\%$ 時是屬於可容許誤差之範圍，元件值於 $\pm 5\%$ 至 $\pm 50\%$ 之間屬於軟性故障[4]，而硬性故障會造成開路或短路導致電路不能正常運作。

近年來有關故障診斷的方法，已經有相當多的文獻，例如採用分層故障診斷(hierarchical fault diagnosis)[5]、類神經網路(neural networks)[6]、灰關聯分析(grey relation diagnosis)[7]、模糊理論(fuzzy theory)[8]等許多不同的方法，因此，本文提出了一種新方法，利用可拓類神經網路對軟性故障的電路做探討，可拓理論為分類處理故障類型且建立物元模型，並計算特徵和故障種類的關聯度，類神經網路主要特色是平行處理與學習能力，本文把兩者結合提出了一種新的故障診斷方法，本方法架構簡單，學習速度快及辨識率高[9-10]。本研究以可拓類神經網路為主體的架構，同時與多層神經網路(MNN)和 k-mean 等方法比較其差異性，並證實其極具實用價值。

2. 可拓類神經網路第一型簡介

可拓理論為分類處理提供一種新的估聯度計算方法；而類神經網路之主要特色是平行處理與學習能力。因此，兩者之結合提供了一種新的分類辨識方法。可拓類神經網路可執行需具有範圍的特徵值、可做監督式學習、具連續輸入和離散輸出等之分類問題。

2.1 可拓類神經網路第一型的架構

圖 1 是可拓類神經網路第一型的基本架構。可拓類神經網路第一型包含輸入層與輸出層。在輸入層過程中的節點得到一個特徵樣本並且使用一個設定的權重參數產生一個輸入模式的影像。在這網路架構裡，每個輸入節點跟輸出節點皆有兩個權重連接；一個權重代表此節點的輸入特徵的最小值，另一個權重則代表節點的輸入特徵的最大值。例如在 j -th 輸入節點和 k -th 輸出節點連結的是 W_{kj}^U 和 W_{kj}^L 。




圖 1. 可拓類神經網路第一型的基本架構

2.2 可拓類神經網路第一型的學習法則

可拓類神經網路的學習法則是監督式的學習，可拓類神經由學習調整權重，使其達到與目標相同的輸出值或降低輸出值的誤差。在學習之前，有幾個變數需先定義。設學習樣本為 $X = \{x_1, x_2, \dots, x_{N_p}\}$ ，而 N_p 為所有的訓練樣本。第 i -th 樣本為 $X_i^p = \{x_{i1}^p, x_{i2}^p, \dots, x_{in}^p\}$ ，所有的特徵樣本為 n ，並設 i -th 樣本的種類為 p 。為了評估可拓類神經網路預測的正確性，把所測試的總誤差設為 N_m ，而總誤差比率設為 E_T ，定義如下：

$$E_T = \frac{N_m}{N_p} \quad (1)$$

以下是可拓類神經網路的學習法則：

步驟一：設定連接輸入節點與輸出節點間的權重根據特徵的模型。

$$w_{kj}^U = \text{Max}_{i \in N_p} \{x_{ij}^k\} \quad (2)$$

$$w_{kj}^L = \text{Max}_{i \in N_p} \{x_{ij}^k\} \quad (3)$$

步驟二：計算每個特徵的權重的中間值。

$$Z_k = \{z_{k1}, z_{k2}, \dots, z_{kn}\} \quad (4)$$

$$Z_{kj} = \left(w_{kj}^L + w_{kj}^U \right) / 2 \quad (5)$$

for $k=1, 2, \dots, n_c$; $j=1, 2, \dots, n$

步驟三：讀取 i -th 訓練樣本以及特徵數 p 。

$$X_i^p = \{x_{i1}^p, x_{i2}^p, \dots, x_{in}^p\}, \quad p \in n_c \quad (6)$$

步驟四：使用可拓距離來計算樣本跟 k -th 群聚的距離，而其數學式如下：

$$ED_{ik} = \sum_{j=1}^n \left[\frac{|x_{ij}^p - z_{kj}| - (w_{kj}^U - w_{kj}^L) / 2}{(w_{kj}^U - w_{kj}^L) / 2} + 1 \right] \quad (7)$$

for $k=1, 2, \dots, n_c$

步驟五：找 k^* ， $ED_{ik^*} = \min\{ED_{ik}\}$ 。若 $k^* = p$ 則至步驟七；否則至步驟六。




圖 2. 可拓距離曲線圖

步驟六：新 p -th 和 k^* -th 的權重值如下：

(a) 更新 p -th 和 k^* -th 的權重中間值：

$$z_{pj}^{new} = z_{pj}^{old} + \eta(x_{ij}^p - z_{pj}^{old}) \quad (8)$$

$$z_{k^*j}^{new} = z_{k^*j}^{old} - \eta(x_{ij}^p - z_{k^*j}^{old}) \quad (9)$$

更新 p -th 和 k^* -th 的權重值：

$$w_{pj}^{L(new)} = w_{pj}^{L(old)} + \eta(x_{ij}^p - z_{pj}^{old}) \quad (10)$$

$$w_{pj}^{U(new)} = w_{pj}^{U(old)} + \eta(x_{ij}^p - z_{pj}^{old}) \quad (11)$$

$$w_{k^*j}^{L(new)} = w_{k^*j}^{L(old)} + \eta(x_{ij}^p - z_{k^*j}^{old}) \quad (12)$$

$$w_{k^*j}^{U(new)} = w_{k^*j}^{U(old)} + \eta(x_{ij}^p - z_{k^*j}^{old}) \quad (13)$$

其中 η 為學習率。

步驟七：重複步驟三到步驟六，直到所有樣本都已分類完成。

步驟八：若分類處理已達到收斂或是總誤差率達到一個最小的標準值則停止，否則回到步驟三。

2.3 可拓類神經網路第一型的辨識階段

當可拓類神經網路完成學習後，即可進行分類或辨識。其演算法如下：

步驟一：讀取可拓類神經網路已學習的權重矩陣。

步驟二：計算每個中心的中間值，如式(4)和(5)。

步驟三：讀取測試樣本。

$$X_i = \{x_{i1}, x_{i2}, \dots, x_{in}\} \quad (14)$$

步驟四：使用所提的可拓距離來計算測試樣本跟每個群聚的距離，如方程式(7)。

步驟五：找 k^* ，利用 $ED_{ik^*} = \min\{ED_{ik}\}$ ，以及設定 $O_{ik^*} = 1$ 的群聚類別。

步驟六：假設所有測試樣本都被分類完成，則停止，否則回到步驟三。

3. 模擬故障診斷

本文以二階高通濾波器作為測試模擬電路，如圖 3 所示。高通濾波器是指讓高於截止頻率之訊號通過，讓低於截止頻率之訊號衰減之電路，對於不同濾波器而言，每個頻率信號之衰減程度會有所不同。此電路運用在音頻時，它是被稱為低頻濾波器。本文二階濾波器增益為 1.586，截止頻率為 7.96kHz。節點 1 和 2 是測量節點，此兩節點可測量或模擬出暫態電壓與相位頻率。表 1 則為電路元件和規格。




圖 3. 二階高通濾波器電路

表 1. 高通濾波器之元件

元件名稱	規格
R1	1K Ω
R2	1K Ω
R3	1K Ω
R4	586 Ω
C1	20nF
C2	20nF

3.1 模擬各種電路故障

表 2. 各元件參數性故障值與容錯範圍值

元件名稱	規格	$\pm 5\%$ 之數值	$\pm 20\%$ 之數值
R1	1 K Ω	1.05 K Ω	1.2 K Ω
		0.95 K Ω	0.8 K Ω
R2	1 K Ω	1.05 K Ω	1.2 K Ω
		0.95 K Ω	0.8 K Ω
R3	1 K Ω	1.05 K Ω	1.2 K Ω
		0.95 K Ω	0.8 K Ω
R4	586 Ω	615.3 Ω	703.2 Ω
		556.7 Ω	468.8 Ω
C1	20 nF	21 nF	24 nF
		19 nF	16 nF
C2	20 nF	21 nF	24 nF
		19 nF	16 nF

為了模擬電路各種狀況，本研究利用 PSPICE 軟體分別以正常與各種故障類型情況下模擬，電路元件正常之可容錯範圍為 $\pm 5\%$ ，軟性故障為 $\pm 20\%$ 。設電路中之 R1、R2、R3、R4、C1、C2 為故障元件，經由靈敏度分析針對每一元件之每一個誤差參

數作模擬，表 2 為每單一元件之參數性故障和正常範圍值。

在研究中之測量點為節點 1 與節點 2，此兩節點分別以暫態電壓(V)與相位頻率(P)為 4 個檢測信號，並以正常和各種故障情況模擬。圖 4、圖 5、圖 6、圖 7 顯示在節點 1 與節點 2 以無誤障和各種故障類型模擬所得之暫態電壓(V)的 RMS 值和相位頻率(P)。利用蒙地卡羅針[11]對每個故障類型各產生出 30 筆訓練資料，在訓練階段；各種故障類型可建立出 11 筆之物元模型。




圖 4. 節點 1 在軟性故障及無故障時之相位角曲線




圖 5. 節點 2 在軟性故障及無故障時之相位角曲線




圖 6. 節點 1 在軟性故障及無故障時電壓 RMS 值曲線




圖 7. 節點 2 在軟性故障及無故障時電壓 RMS 值曲線

3.2 故障診斷流程圖

由於電路之元件值存有誤差值，會因此造成電路特性的偏移，因此透過以學習過的可拓類神經網路第一型進行故障診斷，並分析元件誤差對電路特性之影響程度。在本研究中，電路之故障類型可分為 11 種類型(1 為正常，10 為軟性故障)，利用 PSPICE 軟體進行各種故障模擬，再從故障之數據來進行辨識。圖 8 為系統流程圖。

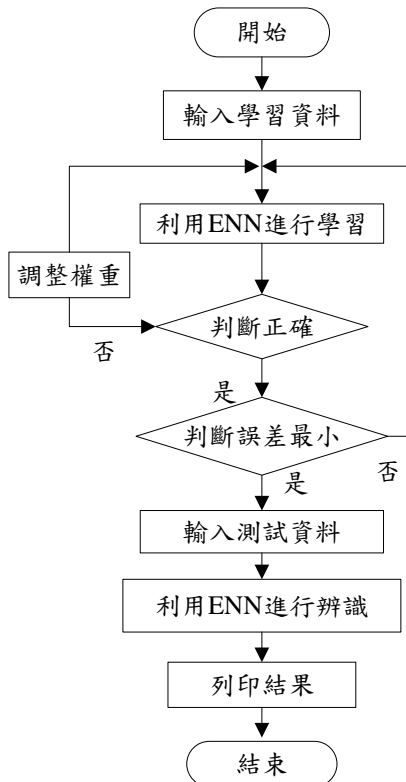


圖 8. 系統流程圖

4. 測試結果與討論

本文故障類型分成 11 類，每種故障類型都利用 PSPICE 軟體模擬各 30 筆的資料，總共有 390 筆數

據做為訓練樣本對所架構之診斷系統完成訓練後，即可對系統進行故障之診斷。表 3 為蒙地卡羅產生訓練樣本。表 4 為參數性故障辨識後之關聯度，例如，表 4 裡的第 3 筆數據和第 1 類型之關聯度是最小的，所是為無故障。本文所提出的方法不僅可以診斷出電路故障類型，也可從得之關聯度資料發現電路潛在故障因素，在未來可提早對電路進行維修以預防更嚴重的故障。

表 3 各種故障類型之數據樣本(部分資料)

No.	V ₁	V ₂	P ₁	P ₂	故障類別	故障狀況
3	4.75	7.89	73	136	1	無故障
44	6.46	8.98	76	136	2	R1 超過標準值
75	3.95	6.88	69	135	3	R1 低於標準值
140	4.76	7.93	69	132	4	R2 超過標準值
195	4.95	8.02	77	139	5	R2 低於標準值
235	4.52	8.0	72	135	6	R3 超過標準值
268	5.21	7.89	75	138	7	R3 低於標準值
290	4.62	7.93	74	137	8	R4 超過標準值
315	5.11	8.02	71	134	9	R4 低於標準值
350	4.77	7.92	73	133	10	C2 超過標準值
385	4.91	8.01	72	138	11	C2 低於標準值

表 5 各種方法辨識之準確率比較

方法	訓練次數	準確率(%)
ENN-1	N/A	99%
K-means	N/A	92%
MNN I (4-8-11)	1000	79%
MNN II (4-9-11)	1000	90%
MNN III (4-10-11)	1000	92%

表 5 顯示本文所提出之方法與 k-mean、MNN 方法作比較。其中 MNN 準確率為 79%，在 k-mean 準確率為 92%；而利用可拓類神經第一型準確率為 99%。這也驗證了本文所提出的方法是優過於其他方法。為了驗證可拓類神經第一型診斷之容錯能力，同時考慮到人為疏失、環境因素、導線老化等等的的不確定性，在實際測試時，樣本資料分別加入±5%和±10%的雜訊，再利用本文方法在進行辨識，表 6 為加入不同雜訊後的辨識準確率，而由表中可知，可拓類神經網路第一型加入雜訊時，其誤差會增加，但所判斷出來的準確率和依舊相當高，更優過於 k-mean 和 MNN 方法，此外，本文方法能表示出更好的容錯能力，並具有較高的準確度。

表 4 可拓類神經網路第一型診斷後之關聯度(部分結果)

NO	1	2	3	4	5	6	7	8	9	10	11	診斷結果
3	1	12.59	15.33	3.44	2.8	3.83	4.59	1.92	3.84	2.36	2.31	1
44	29.3	1	59	30.95	25.63	35	23.06	27	32.4	29.7	30.6	2
75	13.12	19.28	1	11.68	12.37	10.85	15.45	12.4	12.5	12.54	13.3	3
140	9.56	23.82	23.5	1	6.35	8.24	15.3	9.15	7.1	5.18	8.5	4
195	4.1	7.86	13.8	3.76	1	6.67	3.03	2.63	5.73	3.8	2.8	5
235	4.13	15.97	16.93	4.12	4.88	1	8.36	4.12	2.9	3.64	4.6	6
268	4.34	11.1	19	5.62	3.15	8.04	1	2.84	6.37	4.85	3.48	7
290	4	20.86	26.57	6.84	4.38	7.2	5.9	1	8.13	5.04	4.39	8
315	3.37	10.44	14.6	2.94	3.75	2.93	5.05	4.5	1	2.63	3.79	9
350	3.37	17.5	21.2	2.86	4.16	4.37	8.3	4.6	4.13	1	5.1	10
385	3.81	17.32	23.79	5.31	3.55	7.01	5.51	4	5.4	5.47	1	11

表 6 加入雜訊之診斷結果

輸入雜訊(%)	ENN-1	K-means	MNN
±0	99%	92%	92%
±5	83%	56%	66%
±10	75%	39%	45%
±15	71%	32%	39%

5. 結論

本文對電路故障分析，經由測試結果得知，本文所提出來的可拓類神經網路第一型，與 k-mean 及多層神經網絡方法比較後，可以明顯看出，辨識出來的準確率皆高於其他方法，且有相當高的容錯能力，而架構上較簡單，因此，也驗證了可拓類神經網路第一型在故障診斷上的可行性。未來也可把這項技術應用在其他方面，例如變壓器及轉換器故障診斷分析等等功能。

6. 參考文獻

- [1] S. Yongkui, C. Guangju, L. Hui, "Analog Circuits Fault Diagnosis Using Support Vector Machine," International Conf. Communications Circuits and Systems, 2007, ICCAS 2007, pp. 1003-1006, 2007.
- [2] M. Slamani, B. Kaminska, "Fault Observability Analysis of Analog Circuits in Frequency Domain," IEEE Trans. Circuits Systems II, Analog and Digital Signal Proc., pp. 134-139, 1996.
- [3] Z. You, E. S. Sinencio, J. P. Gyvez, "Analog System-Level Fault Diagnosis Based on a Symbolic Method in Frequency Domain," IEEE Trans. Instrumentation and Meas., Vol. 44, No. 1, pp. 28-35, Feb, 1995.
- [4] M. Catelani, A. Fort, "Soft Fault Detection and Isolation in Analog Circuits: Some Results and a Comparison Between a Fuzzy

Approach and Radial Basis Function Networks," IEEE Trans. Instrumentation and Meas., Vol. 51, pp. 196- 202, 2002.

- [5] C. K. Ho, P. R. Shepherd, F. Eberhardt, and W. Tenten, "Hierarchical Fault Diagnosis of Analog Integrated Circuits," IEEE Trans. Circuits and Systems-I: Fundamental Theory and Applications, Vol. 48, No. 8, pp. 921-929, August, 2001.
- [6] L. Yuan, Y. He, J. Huang, Y. Sun, "A New Neural-Network-Based Fault Diagnosis Approach for Analog Circuits by Using Kurtosis and Entropy as a Preprocessor," IEEE Trans. Instrument and Meas., Vol. 59, No. 3, pp. 196-202, 2010.
- [7] M. H. Zhang, S. J. Lv, D. H. Wang, Y. X. Song, H. Liu, "Research on Fault Diagnosis Methods with Grey Relation Analysis," Proceedings of 2009 IEEE International Conf. Grey Systems and Intelligent Services, pp. 72-75, 2009.
- [8] M. Catelani, A. Fort, C. Alippi, "A Fuzzy Approach for Soft Fault Detection in Analog Circuits," Meas, Vol. 32, pp. 73-83, 2002.
- [9] M. H. Wang, C. P. Hung, "Extension Neural Network and Its Applications," Neural Networks, Vol. 16, pp. 779-784, 2003.
- [10] M. H. Wang, C. P. Hung, "Extension Neural Network," Proceedings of the International Joint Conference on Neural Networks, Vol. 1, pp. 399-403, 2003.
- [11] 鄭光欽，電路程式 OrCAD PSpice 9.x，全威圖書有限公司，2003 年 7 月。