

## ELVQ 算法实现宽参数偏移的多故障电路诊断

徐崇斌<sup>①</sup> 赵志文<sup>\*①②</sup> 郑慧芳<sup>③</sup>

<sup>①</sup>(北京师范大学信息科学与技术学院 北京 100875)

<sup>②</sup>(北京航空航天大学惯性技术国防科技重点实验室 北京 100191)

<sup>③</sup>(中国科学院电子学研究所 北京 100190)

**摘要:** 该文提出了一种强化自适应策略的学习矢量量化(Enhanced Learning Vector Quantization, ELVQ)算法,并设计了基于 SOM(Self-Organizing Map)-LVQ 模型的故障分类方法,用于实现宽参数偏移的模拟电路多故障诊断。该文算法具有两方面的优势:一方面利用获胜神经元数目的自适应,均衡了神经元的获胜概率;另一方面根据样本分类结果计算作用因子修正神经元的权值,增强了类别边界决策性能。仿真结果表明,所提出的算法具有收敛速度快,分类误差小等特点。

**关键词:** 模拟电路; 多故障诊断; 学习矢量量化; 宽参数偏移; ELVQ 算法

中图分类号: TP183; TP206<sup>+</sup>.3

文献标识码: A

文章编号: 1009-5896(2011)06-1520-05

DOI: 10.3724/SP.J.1146.2011.00011

## Multi-fault Diagnosis for Wide-deviation Analog Circuits Based on ELVQ Algorithm

Xu Chong-bin<sup>①</sup> Zhao Zhi-wen<sup>①②</sup> Zheng Hui-fang<sup>③</sup>

<sup>①</sup>(School of Information, Beijing Normal University, Beijing 100875, China)

<sup>②</sup>(Key Lab of Inertial Technology for National Defense, Beihang University, Beijing 100191, China)

<sup>③</sup>(Institute of Electronics, Chinese Academy of Sciences, Beijing 100190, China)

**Abstract:** In order to realize the multi-fault diagnosis for wide-deviation analog circuits, this paper designs a classification model based on Self-Organizing Map-Learning Vector Quantization(SOM-LVQ) network, and also presents an Enhanced LVQ (ELVQ) algorithm, in which the win-probability of neural can be balanced and the point density of the neural around the Bayesian decision surfaces can be reduced. The results of simulation indicate that the proposed algorithm has advantages of rapid convergence and low classification error.

**Key words:** Analog circuits; Multi-fault diagnosis; Learning Vector Quantization (LVQ); Wide-deviation; Enhanced LVQ (ELVQ) algorithm

### 1 引言

模拟电路故障诊断的研究从上世纪 60 年代开始,得到了国内外研究者的广泛关注,取得了大量的研究成果。由于模拟电路本身的特性,使其具有故障建模困难、元件容差和非线性等特点,这给模拟电路的故障诊断带来了极大的挑战<sup>[1]</sup>。

在模拟电路故障诊断研究的早期,主要以一些传统的方法为主,有故障字典法、参数识别法、故障验证法、逼近法和网络撕裂法<sup>[2]</sup>。近年来,随着机器学习方法的出现,模拟故障诊断领域迎来了新的发展,由于其利用数据驱动的思想而无需对被测电路建立物理模型,表现出良好的发展前景,文献[1]

训练 BP 网络作为故障字典对电路的响应信号进行故障分类;文献[3,4]在文献[1]的基础上运用小波变换和主成分分析(PCA)对响应信号进行预处理后,再用 BP 网络进行训练,大大降低了网络神经元规模;文献[5]通过提取信号中负熵和峭度两个非高斯性度量作为响应信号的特征对 BP 网络进行训练,利用简约的网络结构取得了较好的诊断效果;文献[6]将 SOM(Self-Organizing Map)神经网络用作聚类预处理结合支持向量机(SVM)理论生成二叉树 SVMs 网络对电路故障进行分类,获得了较高的分类精度。然而以上运用机器学习方法进行诊断时,普遍存在两个问题<sup>[2,7]</sup>:

(1)故障元件参数设为特定值,使得故障特征过于集中,无法体现每类故障特征的统一特性;

(2)对电路单故障的诊断的研究较多,而对多故

障的诊断问题的研究则较少涉及, 由此带来的特征空间重合问题尚未得到深入的研究。

针对上述问题, 本文提出了 ELVQ 算法, 并设计了以 SOM-LVQ 网络为基础的诊断方法, 对小波分解得到系数矩阵进行主成分分析和故障分类。文章通过两个典型滤波器电路在宽参数偏移条件下单双故障的仿真实验, 从网络的收敛速度和分类精度方面对 ELVQ 算法进行了验证。

## 2 响应信号的特征提取

特征提取是模拟电路故障诊断中关键的一步, 若提取的不同类别故障信号的特征在对应的特征空间上存在重叠, 可能导致后期神经网络对某些故障类别分类误差偏大而无法收敛等问题。响应信号的特征提取流程如图 1 所示。




图 1 训练集和测试集信号故障特征提取流程

假设经 PSPICE 仿真后的原始响应信号的长度为  $L$ , 用于训练的响应信号数目为  $n$ , 先将响应信号分为训练集和测试集, 利用时频分析的方法对训练集和测试集进行  $k$  层小波分解, 再通过 PCA 估计训练集小波系数的  $(kl+l) \times n$  维主成分矩阵  $F = [F_1, F_2, \dots, F_{k+1}]^T$ , 将其归一化后作为代表电路响应信号的特征, 为了保证网络对测试集的认识, 待训练集小波系数的 PCA 和归一化后, 测试集需要利用训练集处理时的 PCA 坐标系和归一化映射, 得到测试集的特征。下面讨论训练集的特征提取。

## 3 用于多故障分类的 SOM-LVQ 网络

### 3.1 SOM-LVQ 网络模型

假设故障集为  $Y$ , SOM 层神经元的  $q$  维拓扑空间为  $\Omega$ , 图 2 给出了当  $q=2$  时典型的 SOM-LVQ 网络模型, 网络结构分为 3 层: 输入层是取自响应信号特征矩阵  $F$  (记为空间  $X$ ) 的特征样本, 对所有输入的特征样本通过先验知识加以标识, 记为  $s_t = (x_t, y_t)$ , 其中  $x_t \in X, y_t \in Y$ ; 中间层是 SOM 层, 负责完成从特征空间  $X$  到空间  $\Omega$  的映射  $M_{\text{som}}$ ; 输出层由故障集构成, 完成神经元拓扑空间  $\Omega$  到有限集  $Y$  的映射  $M_{\text{out}}$ , 记为  $s_t = (c_t, y_t)$ , 其中  $c_t \in \Omega, y_t \in Y$ 。




图 2 3 层 SOM-LVQ 网络模型

### 3.2 ELVQ 算法描述

Kohonen 在文献[8]中提出有监督的 LVQ 训练算法, 本文通过引入自适应获胜神经元数目和基于作用因子的权值调整算法, 提出 ELVQ 算法对 LVQ 算法进行了改进。我们将 ELVQ 算法分为拓扑排序和优化调整两个阶段: 在拓扑排序阶段先用 SOFM 算法对权值进行调整, 并采取 RL 算法[9](Relabeling Algorithm)对映射  $M_{\text{out}}$  进行更新; 达到阶段转换条件后, 进入优化调整阶段对网络进行有监督的训练。

假设给定的 SOM 网络层神经元数目为  $n_c$ , 输入特征样本为  $x_t$ , 神经元  $c_i$  的权向量为  $\omega_i$ , 其中  $x_t \in X, i = 1, 2, \dots, n_c$ 。当样本  $x_t$  输入时, 计算  $x_t$  与所有神经元权向量的欧氏距离并将计算结果构成集合  $\Gamma$ , 通常定义  $c_w$  为获胜神经元, 若满足

$$\|x_t - c_w\| = \min_i \Gamma, i = 1, 2, \dots, n_c \quad (1)$$

在优化调整阶段, 为均衡神经元的获胜概率, 定义自适应的获胜神经元集合  $N_c$ ,  $N_c$  的生成算法如图 3 所示。得到获胜神经元集合  $N_c$  后, 集合  $N_c$  中神经元对应的码矢  $\omega_i$  根据式(2)来更新它的权值:

$$\omega_i(t+1) = \begin{cases} \omega_i(t) + \Delta\omega_i(t), & i \in N_c \\ \omega_i(t), & \text{其他} \end{cases} \quad (2)$$

式中  $\Delta\omega_i(t)$  表示集合  $N_c$  中第  $i$  个码矢调整的方向和大小, 优化调整阶段与传统方法不同, 根据  $f(x_t, \omega_i)$

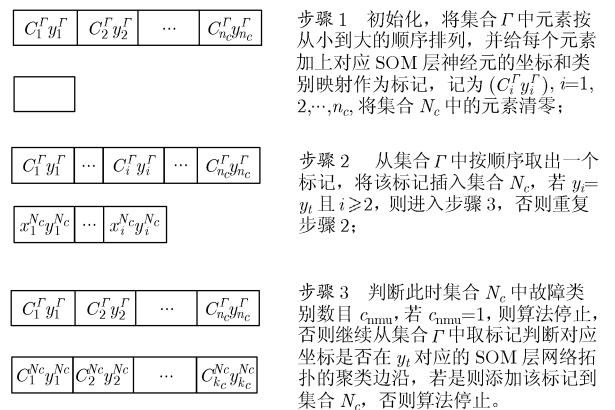


图 3 自适应获胜神经元集合  $N_c$  生成算法步骤

和  $h(x_i, \omega_i)$  两个作用因子确定  $\Delta\omega_i$ :

$$\Delta\omega_i(t) = \begin{cases} -\alpha(t)f(x_i, \omega_i)[x_i - \omega_i], & y_i \neq y_i \\ \alpha(t)h(x_i, \omega_i)[x_i - \omega_i], & y_i = y_i \end{cases} \quad (3)$$

其中拒绝因子  $f(x_i, \omega_i)$  当  $N_c$  中神经元标识和输入样本不同时起作用, 目的是在保证对本类分类影响最小的前提下, 远离输入样本  $x_i$ 。我们定义拒绝因子:

$$f(x_i, \omega_i) = \mu_i \left( 1 - \frac{d(x_i, \omega_i)}{\tau_1 \delta_i + \tau_2 \delta_{ii} + d(x_i, \omega_i)} \right), \quad y_i \neq y_i \quad (4)$$

其中  $d(x_i, \omega_i)$  是  $x_i$  和  $\omega_i$  的欧氏距离; 加权系数  $\mu_i$  满足  $-0.5 < \mu_i < 0.5$ , 大小与  $i$  在  $N_c$  的排序成反比;  $\tau_1$  和  $\tau_2$  是离散度加权因子, 分别作为样本  $y_i$  的离散度  $\delta_i$  以及  $y_i$  和  $y_i$  的联合离散度  $\delta_{ii}$  的加权系数, 以控制相对调整量。类似地, 定义接受因子:

$$h(x_i, \omega_i) = \left( \mu_i + \frac{1}{2} \right) \left( 1 - \frac{d(x_i, \omega_i)}{\tau_1 \delta_i + \tau_2 \delta_{ii} + d(x_i, \omega_i)} \right), \quad y_i = y_i \quad (5)$$

在每次迭代结束后, 我们将  $n$  个训练样本依次输入网络, 记录获胜神经元类别标识  $y_i$  和输入样本标识  $y_i$  不同的个数  $n_E$ , 并按式(6)计算训练误差:

$$E = n_E / n \quad (6)$$

ELVQ 算法的具体步骤如下:

步骤 1 令输入层神经元个数和特征维数一致设为  $(kl + l)$ , 输出层神经元数和故障种类均设为  $N_y$ ; 确定中间层网络拓扑结构和神经元数目, 神经元的初始权值向量的每维取小随机数;

步骤 2 从测试样本集中随机选取样本点输入网络并寻找获胜神经元, 对获胜神经元及其邻域按式(3)进行调整, 当测试样本中所有样本均被取了一次, 用 RL 算法对神经元的类别标识进行更新;

步骤 3 更新学习率和邻域函数, 将训练样本输入网络进行测试并按式(6)计算训练误差, 判断是否满足条件  $\alpha(t) \leq \alpha_{thr}$  或  $E \leq E_{thr}$ , 若达到条件则进入步骤 4, 否则重复步骤 2 和步骤 3;

步骤 4 同样从测试样本集中随机取出样本点并计算获得集合  $\Gamma$ , 确定集合  $N_c$ , 并用式(3)对  $N_c$  中的元素对应的神经元权值进行调整, 迭代完成后对获胜神经元的类别标识进行更新;

步骤 5 更新学习率, 将训练样本输入网络进行测试并按式(6)计算训练误差, 判断训练误差是否降到给定阈值或规定的迭代次数是否结束, 若满足条件则网络训练完毕, 否则重复步骤 4。

## 4 实验及结果

### 4.1 实验方法及特征提取

本文研究的两个电路<sup>[1,3]</sup>(见图 4), 电路 1 为中心频率为 25 kHz 的 Sallen-Key 带通滤波器, 电路 2 为截止频率为 10 kHz 的四运放高通滤波器。所有元

件的标准值如图所示。研究的故障元件、元件故障及无故障定义遵循文献[1]和文献[3]。本文同时考虑单故障和双故障, 这样两个电路分别具有 33 和 73 种电路状态, 表 1 给出了电路 1 所包含的部分电路状态。

表 1 电路 1 所包含的故障类型和故障元件取值范围

故障类别	故障元件	故障取值	故障类别	故障元件	故障取值
1	-	-	10	$R_2 \uparrow$	1.5~3 k $\Omega$
				$R_3 \uparrow$	3~6 k $\Omega$
2	$R_2 \uparrow$	1.5~3 k $\Omega$	11	$R_2 \downarrow$	0.5~0.1 k $\Omega$
				$R_3 \uparrow$	3~6 k $\Omega$
3	$R_2 \downarrow$	0.5~0.1 k $\Omega$	12	$R_2 \uparrow$	1.5~3 k $\Omega$
				$R_3 \downarrow$	1~0.2 k $\Omega$
4	$R_3 \uparrow$	3~6 k $\Omega$	13	$R_2 \downarrow$	0.5~0.1 k $\Omega$
				$R_3 \downarrow$	1~0.2 k $\Omega$
5	$R_3 \downarrow$	1~0.2 k $\Omega$	$\vdots$	$\vdots$	$\vdots$
6	$C_1 \uparrow$	7.5~15 nF	30	$C_1 \uparrow$	7.5~15 nF
				$C_2 \uparrow$	7.5~15 nF
7	$C_1 \downarrow$	2.5~0.5 nF	31	$C_1 \downarrow$	2.5~0.5 nF
				$C_2 \uparrow$	7.5~15 nF
8	$C_2 \uparrow$	7.5~15 nF	32	$C_1 \uparrow$	7.5~15 nF
				$C_2 \downarrow$	2.5~0.5 nF
9	$C_3 \downarrow$	2.5~0.5 nF	33	$C_1 \downarrow$	2.5~0.5 nF
				$C_2 \downarrow$	2.5~0.5 nF

我们用 PSPICE 对每种电路状态进行 100 次仿真, 为体现宽参数偏移下算法的适应性, 做 Monte Carlo 分析时故障元件的取值范围为超过标准值的 50%~200%或低于标准值的 50%~90%, 而不局限于某一个特定的故障值, 并将得到的电路响应信号样本中的 80%作为训练样本, 20%作为测试样本。

### 4.2 ELVQ 算法精度及效率分析

为评价本文方法的分类精度和收敛速度, 以预处理得到的特征数据作为 SOM-LVQ 网络的输入信号, 对以下几种训练算法进行了比较分析: 算法 1 为 ELVQ 算法, 算法 2 为 SOFM+LVQ3 算法<sup>[10]</sup>, 算法 3 为 SOFM+RL 算法<sup>[9]</sup>。3 种算法的训练误差和效率分析如表 2 和图 5 所示, 可见, 在相同的迭代次数下, 算法 1 的训练误差低于其他两种算法。由于算法 1 在优化调整阶段获胜神经元数目的一般大于 2 个(算法 2 每次固定调整 2 个神经元<sup>[8]</sup>), 而且算法复杂度较高, 故在迭代次数相等的情况下, 算法 1 的训练时间较长。但在训练误差相等的条件下, 算法 1 所需的迭代次数明显较少。

表 2 给出了随着故障类别的增加 3 种算法对测试集的分类精度比较结果。可见, 有监督的自组织网络训练算法比无监督的算法具有更高的精度。对照图 6 还可以得出, 虽然有个别故障的分类结果并不理想, 但是从全局来看, 在有监督算法中经过算

法 1 训练后的分类精度明显较采用算法 2 更优。图 7 给出了电路 1 分类结果的 U-Matrix, 图中的横纵坐标和 SOM 层网络拓扑结构的神经元排列一致, 每个神经元上以数字形式标识了所属故障类别。可

见, U-Matrix 和图 6 给出的结果是一致的。从图 7 还可以看到, 尽管 ELVQ 算法在一定程度上均衡了神经元的获胜概率, 仍然存在个别神经元从未获胜的情况(如标记类别为“0”)。综上, 本文算

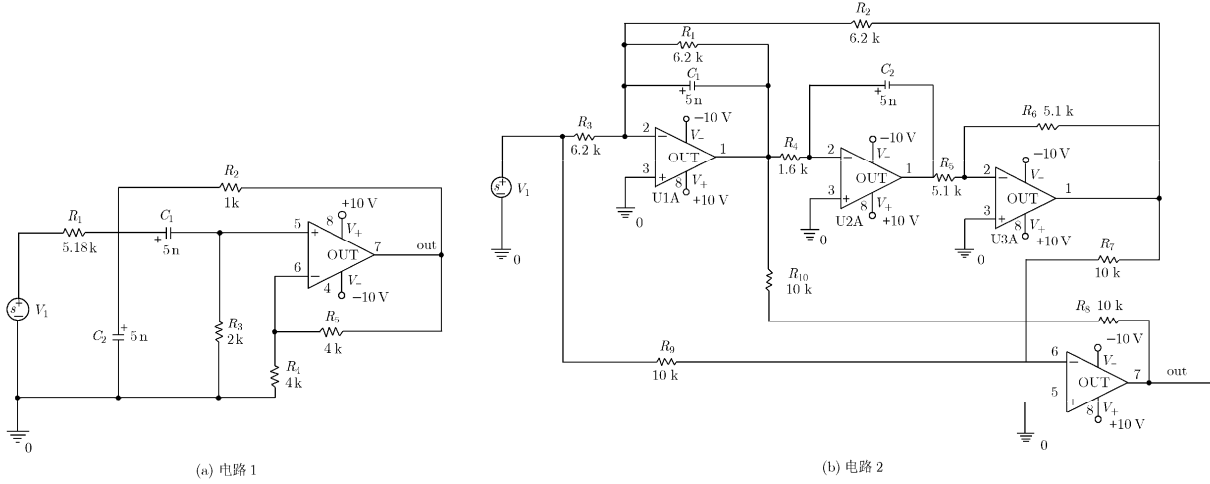


图 4 本文研究的电路 (电阻的单位是  $\Omega$ , 电容的单位是 F)

表 2 3 种算法训练误差和效率比较

	电路 1			电路 2		
	算法 1	算法 2	算法 3	算法 1	算法 2	算法 3
训练误差(%)	1.02	5.72	20.53	3.99	8.92	28.65
测试精度(%)	97.73	93.94	68.03	93.77	88.42	44.11
训练时间(s)	775	576	471	4278	3433	2505




图 5 3 种算法的训练误差和迭代次数关系图

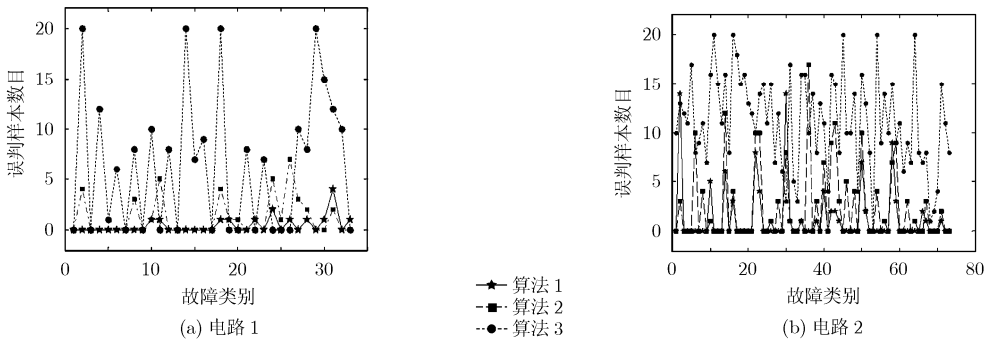


图 6 3 种算法训练的网络对测试集的分类误差结果

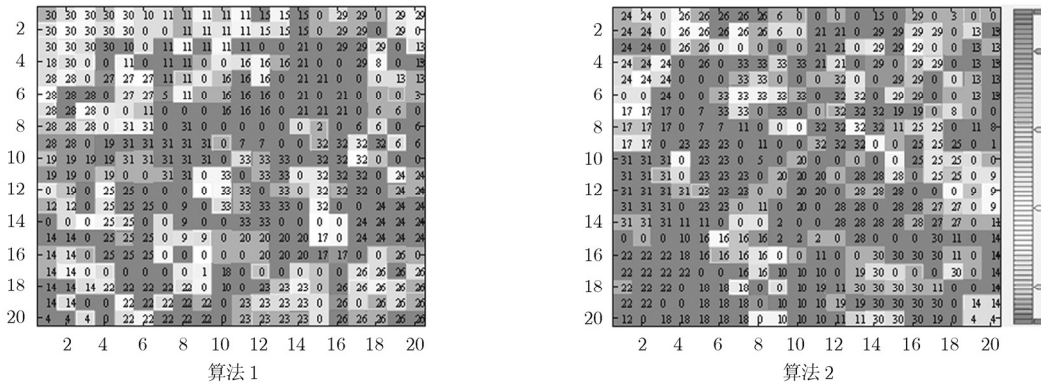


图 7 电路 1 分类结果的 U-Matrix

法在全局分类效果上是有明显的优势，但对个别特征较弱且孤立而离散分布的故障类别的分类效果还不太理想，且依然存在神经元利用率略低的问题。

### 5 结论

针对宽参数偏移的多故障电路诊断问题中故障特征离散及重叠等特点，本文提出了一种强化自适应策略的 ELVQ 算法，仿真实验结果显示，本文提出的算法对典型电路的多故障诊断精度和收敛速度优于其他算法，有效地提高了故障的分类效果，为模拟电路的复杂故障诊断提供了新的思路。同时，从 U-Matrix 中可以得到不同元件电路故障特征的概率密度及其相互关系，对模拟电路的设计时的可靠性分析和元件选型有一定的参考意义。

### 参 考 文 献

[1] Spina R and Upadhyaya S. Linear circuit fault diagnosis using neuromorphic analyzers[J]. *IEEE Transactions on Circuits and Systems-II: Analog and Digital Signal Processing*, 1997, 44(3): 188-196.

[2] 杨士元, 胡梅, 王红. 模拟电路软故障诊断的研究[J]. *微电子学与计算机*, 2008, 25(1): 1-8.  
Yang Shi-yuan, Hu Mei, and Wang Hong. Study on soft fault diagnosis of analog circuits[J]. *Microelectronics & Computer*, 2008, 25(1): 1-8.

[3] Aminian M and Aminian F. A modular fault-diagnostic system for analog electronic circuits using neural networks with wavelet transform as a preprocessor[J]. *IEEE Transactions on Instrumentation and Measurement*, 2007, 56(5): 1546-1554.

[4] 谭阳红, 叶佳卓. 模拟电路故障诊断的小波方法[J]. *电子与信息学报*, 2006, 28(9): 1748-1751.

Tan Yang-hong and Ye Jia-zhuo. Wavelet method for fault diagnosis of analogue circuits[J]. *Journal of Electronics & Information Technology*, 2006, 28(9): 1748-1751.

[5] Yuan Li-fen, He Yi-gang, Huang Jiao-ying, and Sun Yi-chuang. A new neural-network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor[J]. *IEEE Transactions on Instrumentation and Measurement*, 2010, 59(3): 586-595.

[6] Wang An-na and Liu Jun-fang. An improved multiclassifier for soft fault diagnosis of analog circuits[J]. *Lecture Notes in Electrical Engineering*, 2008, 6(9): 129-139.

[7] 周东华, 胡艳艳. 动态系统的故障诊断技术[J]. *自动化学报*, 2009, 35(6): 748-758.  
Zhou Dong-hua and Hu Yan-yan. Fault diagnosis techniques for dynamic systems[J]. *Acta Automatica Sinica*, 2009, 35(6): 748-758.

[8] Kohonen T. The Self-Organizing Map[J]. *Proceedings of the IEEE*, 1990, 78(9): 1464-1480.

[9] Pal N R, Bezdek J C, and Tsao E C K. Generalized clustering networks and kohonen's self-organizing scheme[J]. *IEEE Transactions on Neural Networks*, 1993, 4(4): 549-557.

[10] Demirhan A and Guler I. Combining stationary wavelet transform and self-organizing maps for brain MR image segmentation[J]. *Engineering Applications of Artificial Intelligence*, 2010, 9(8): 1-10.

徐崇斌: 男, 1984 年生, 博士, 研究方向为故障诊断与信号处理。  
赵志文: 男, 1966 年生, 副教授, 研究方向为信号处理、电子系统可靠性。  
郑慧芳: 女, 1983 年生, 博士, 研究方向为雷达信号分析与处理。