

基于小波神经网络的电力电子电路故障模式识别

李微, 谭阳红, 彭永进

(湖南大学电气与信息工程学院, 湖南 长沙 410082)

摘要: 提出了基于两种不同小波神经网络的电力电子电路故障模式识别方法。针对电力电子电路故障, 构造了激活函数型和权值型两种不同的三层小波神经网络, 给出了相应的数学模型和学习算法。以三相整流桥电路为例, 建立了小波神经网络的输出与故障元之间的对应关系, 实现了电路故障的模式识别, 并与用普通 BP 网络识别的结果进行了比较。仿真结果验证了两种故障识别方法的正确性和较好的准确性。

关键词: 小波; 神经网络; 故障模式识别; 电力电子电路

中图分类号: TM13 文献标识码: A 文章编号: 1003-4897(2005)14-0082-05

0 引言

随着电力电子电路的应用日益广泛, 故障识别问题越来越突出。电力电子电路的故障大多数表现为晶闸管的损坏, 其中晶闸管的开路 and 短路最为常见。电力电子电路构成的装置发生故障后, 为了避免故障的扩大, 必须快速 (数毫秒到数十毫秒内) 将主电路停电, 以便操作人员在电力电子电路不通电的条件下, 迅速判断出故障元件, 并更换损坏的元件, 恢复生产。这有赖于操作人员经验和熟练程度。但是, 由于受到现场环境和人为因素的影响, 即使是经验丰富的操作人员都可能出现误判断, 从而延长了停机维修的时间, 影响了生产。因此, 在电力电子电路中应用自动故障识别技术, 是有其现实意义和经济意义的^[1]。近年来, 国内外有关研究人员针对电力电子电路故障识别做了许多有效的研究, 其中有相当一部分是基于神经网络的分析方法^[2~5], 这种方法当识别种类增多, 网络输入的采样信号夹杂着噪声增大时, 识别的准确性就会受到很大的影响。

小波神经网络 (简称小波网络) 是神经网络和小波理论结合的产物^[6]。它兼具了小波多尺度分辨的能力和神经网络并行计算的能力, 有收敛速度快, 鲁棒性好, 逼近能力强等优点, 因而成为研究的热点^[7]。

本文提出基于小波神经网络的故障识别方法。针对电力电子电路故障, 采用自适应 BP 算法, 构造了激活函数型小波网络和权值型小波网络。以三相整流桥电路为例, 建立了小波神经网络的输出与故障元之间的对应关系, 实现了电路的故障识别, 最后, 对两种网络与普通 BP 神经网络的识别结果进

行了比较研究。

1 小波神经网络

小波变换是一种信号的时间 - 尺度 (时间 - 频率) 分析方法, 它在时间域和频率域都具有表征信号的能力, 而且具有多分辨分析的特点, 即在低频部分具有较高的频率分辨率和较低的时间分辨率, 在高频部分具有较高的时间分辨率和较低的频率分辨率。对于任意函数的连续小波变换为:

$$W_f(a, b) = \langle f, \psi_{a,b} \rangle = \int_{-\infty}^{\infty} f(t) \psi_{a,b}^*(t) dt \quad (1)$$

其逆变换公式为:

$$f(t) = C^{-1} \int_0^{\infty} \int_{-\infty}^{\infty} W_f(a, b) \psi_{a,b}(t) \frac{da db}{a^2} \quad (2)$$

其中: 小波 $\psi_{a,b}$ 需满足其容许性条件。

神经网络与小波分析的结合方式有两种, 这里采用紧致型结合方式: 用小波函数作为神经网络的激活函数或权值, 前者称为激活函数型小波网络, 后者称为权值型小波网络。

1.1 激活函数型小波网络

激活函数型小波网络三层网络结构如图 1 所示。

设系统的输入为 $x = [x_1, x_2, \dots, x_N]^T$, $y = [y_1, y_2, \dots, y_S]^T$ 为输出值, 小波函数 $\psi_{a,b}(\cdot)$ 为第一层激活函数, 其中, a 和 b 分别为尺度和位移因子, 第二、三层的传递函数为 $\sigma(\cdot)$ 。第一、二、三层的权值和神经元个数分别为 $w_{1k,n}, w_{2m,k}, w_{3s,m}, K, M, S$, 则网络的输出为

$$y_s = \left[\sum_{m=1}^M w_{3s,m} \left(\sum_{k=1}^K w_{2m,k} \cdot \psi_{a,b} \left(\sum_{n=1}^N w_{1k,n} \cdot x_n \right) \right) \right] \quad (3)$$

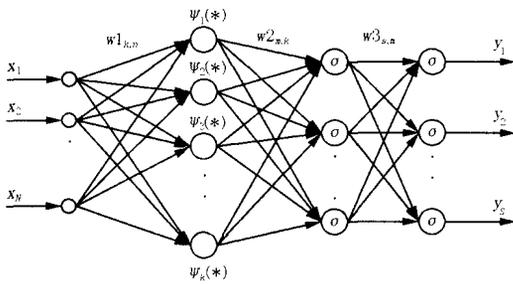


图 1 激活函数型三层小波网络结构

Fig 1 Three-layer wavelet network structure with transfer function

其中: $s=1, 2, \dots, S$, $(*)$ 为 sigmoid 函数。

设输入样本总数为 P , 网络输出层第 s 个节点、第 p 个样本的输出可由式 (1) 计算, 记为 y_s^p , 设其期望值为 \hat{y}_s^p , 定义误差能量函数表达式为

$$e = \frac{1}{2} \sum_{s=1}^S \sum_{p=1}^P (y_s^p - \hat{y}_s^p)^2 \quad (4)$$

设

$$net_k = \sum_{n=1}^N (w1_{k,n} \cdot x_n), \quad a_{,b}(net_k) = \left(\frac{net_k - b_k}{a_k} \right)$$

$$u_1 = \sum_{k=1}^K w2_{m,k} \cdot a_{,b}(net_k), \quad u_2 = \sum_{m=1}^M w3_{s,m} (u_1)$$

有

$$y_s = \left[\sum_{m=1}^M w3_{s,m} \left(\sum_{k=1}^K w2_{m,k} \cdot a_{,b}(net_k) \right) \right] = \left[\sum_{m=1}^M w3_{s,m} (u_1) \right] = (u_2) \quad (5)$$

则由式 (4) 和 (5) 可计算出 e 对 $w1, w2, w3, a, b$ 的偏导数

$$\frac{\partial e}{\partial w3_{s,m}} = - \sum_p (y_s^p - \hat{y}_s^p) \cdot (u_2) \cdot \left(\sum_{k=1}^K w2_{m,k} \cdot a_{,b}(net_k) \right) \quad (6)$$

$$\frac{\partial e}{\partial w2_{m,k}} = - \sum_p \sum_s (y_s^p - \hat{y}_s^p) \cdot (u_2) \cdot w3_{s,m} \cdot (u_1) \cdot a_{,b}(net_k) \quad (7)$$

$$\frac{\partial e}{\partial w1_{k,n}} = - \sum_p \sum_s \sum_m (y_s^p - \hat{y}_s^p) \cdot (u_2) \cdot w3_{s,m} \cdot (u_1) \cdot w2_{m,k} \cdot a_{,b}(net_k) \cdot \frac{x_n^p}{a_k} \quad (8)$$

$$\frac{\partial e}{\partial b_k} = \sum_p \sum_s \sum_m (y_s^p - \hat{y}_s^p) \cdot (u_2) \cdot w3_{s,m} \cdot (u_1) \cdot w2_{m,k} \cdot a_{,b}(net_k) \cdot \frac{1}{a_k} \quad (9)$$

$$\frac{\partial e}{\partial a_k} = \sum_p \sum_s \sum_m (y_s^p - \hat{y}_s^p) \cdot (u_2) \cdot w3_{s,m} \cdot (u_1) \cdot w2_{m,k} \cdot a_{,b}(net_k) \cdot \left(\frac{net_k - b_k}{a_k^2} \right) \quad (10)$$

学习算法采用梯度下降、带动量项和自适应学习率的算法^[8], 记 $w = \{w1_{n,k}, w2_{k,m}, w3_{m,s}\}$, $b = \{b_k\}$, $a = \{a_k\}$, $w = \{w1_{n,k}, w2_{k,m}, w3_{m,s}\}$, $b = \{b_k\}$, $a = \{a_k\}$ 。其反向传播的动量改进 (MOBP) 公式

$$w(t+1) = w(t) - \eta \cdot \frac{\partial e}{\partial w}$$

$$b(t+1) = b(t) - \eta \cdot \frac{\partial e}{\partial b}$$

$$a(t+1) = a(t) - \eta \cdot \frac{\partial e}{\partial a}$$

式中:

$$w(t) = mc \cdot w(t-1) - (1-mc) \cdot lr \cdot \frac{\partial e}{\partial w} \quad (11)$$

$$b(t) = mc \cdot b(t-1) - (1-mc) \cdot lr \cdot \frac{\partial e}{\partial b} \quad (12)$$

$$a(t) = mc \cdot a(t-1) - (1-mc) \cdot lr \cdot \frac{\partial e}{\partial a} \quad (13)$$

在式 (13)、(14) 和 (15) 中, mc 和 lr 分别为动量因子和学习率。其取值如下:

如果 $e(t) > e(t-1) \times er$, 则 $mc = MC_1$, $lr = lr \times dm$;

如果 $e(t) < e(t-1)$, 则 $mc = MC_2$, $lr = lr \times im$

其中, er 为允许最大错误率, MC_1, MC_2 为动量因子常数, dm 为学习率减少率, im 为学习率增长率。

1.2 权值型小波网络

权值型小波网络三层网络结构如图 2 所示。

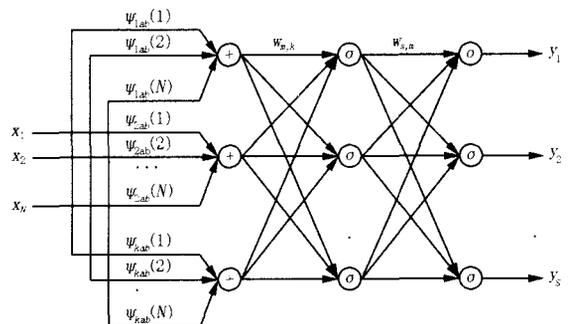


图 2 权值型三层小波网络结构

Fig 2 Weight typed three-layer wavelet network structure

设 $x = [x_1, x_2, \dots, x_N]$ 为输入, $y = [y_1, y_2, \dots, y_S]$ 为输出值, 设第一层的激励函数为线性函数 purelin 函数, 权值 $w_{1,k,n}$ 为

$$w_{1,k,n} = a_{k,b} \left(\frac{n - b_k}{a_k} \right)$$

权值 $w_{1,k,n}$ 的优化通过优化对应的小波变换尺度因子 a_k 和位移因子 b_k 来实现。第二、三层的传递函数为 $(*)$, 权值为 $w_{2,m,k}$ 和 $w_{3,s,m}$ 。网络各层的神经元个数为 K, M, S , 则权值型小波网络输出为

$$y_s = \left[\sum_{m=1}^M w_{3,s,m} \cdot \left(\sum_{k=1}^K (w_{2,m,k} \cdot \sum_{n=1}^N (a_{k,b}(n) \cdot x_n)) \right) \right] \quad (14)$$

其中: $s=1, 2, \dots, S$, $(*)$ 为 sigmoid 函数。

定义网络的误差能量为

$$e = \frac{1}{2} \sum_{s=1}^S \sum_{p=1}^P (y_s^p - \hat{y}_s^p)^2 \quad (15)$$

设

$$net_k = \sum_{n=1}^N (a_{k,b}(n) \cdot x_n),$$

$$u_1 = \sum_{k=1}^K w_{2,m,k} \cdot net_k,$$

$$u_2 = \sum_{m=1}^M w_{3,s,m} \cdot (u_1)$$

则有

$$y_s = \left[\sum_{m=1}^M w_{3,s,m} \cdot \left(\sum_{k=1}^K w_{2,m,k} \cdot net_k \right) \right] = \left[\sum_{m=1}^M w_{3,s,m} \cdot (u_1) \right] = (u_2) \quad (16)$$

则由式 (15) 和 (16) 可计算出 e 对 w, a, b 的偏导数

$$\frac{\partial e}{\partial w_{3,s,m}} = - \sum_p (y_s^p - \hat{y}_s^p) \cdot (u_2) \cdot \left(\sum_{k=1}^K w_{2,m,k} \cdot net_k \right) \quad (17)$$

$$\frac{\partial e}{\partial w_{2,m,k}} = - \sum_p \sum_s (y_s^p - \hat{y}_s^p) \cdot (u_2) \cdot w_{3,s,m} \cdot (u_1) \cdot net_k \quad (18)$$

$$\frac{\partial e}{\partial b_k} = \sum_p \sum_m \sum_n \sum_s (y_m^p - \hat{y}_m^p) \cdot (u_2) \cdot w_{3,s,m} \cdot (u_1) \cdot w_{2,m,k} \cdot a_{k,b}(n) \cdot x_n^p \cdot \frac{1}{a_k} \quad (19)$$

$$\frac{\partial e}{\partial a_k} = \sum_p \sum_m \sum_n \sum_s (y_m^p - \hat{y}_m^p) \cdot (u_2) \cdot w_{3,s,m} \cdot (u_1) \cdot w_{2,m,k} \cdot a_{k,b}(n) \cdot x_n^p \cdot \left(\frac{n - b_k}{a_k} \right) \quad (20)$$

学习算法也可采用梯度下降、带动量项和自适应学习率的 BP 算法。具体计算公式和上节相同, 这里不再赘述。

2 模式识别实例

2.1 基于三相整流桥电路故障模式识别的网络学习样本设计

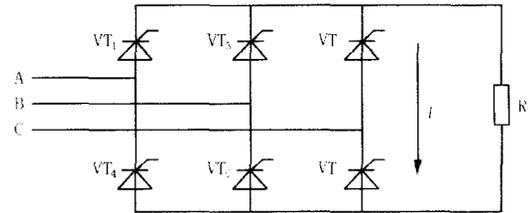


图 3 三相整流桥电路

Fig 3 Three-phase rectifier circuit

图 3 所示为电阻性负载的三相整流桥电路。假设以控制触发角 $\alpha = 0^\circ$ 晶闸管桥臂开路故障为例分析 (包括晶闸管开路、串接熔断器熔断、触发脉冲丢失等故障) 以及最多同时有二路桥臂发生故障。这样可将故障分为五大类, 共 22 小类^[3-5]:

第一大类 (001): 没有晶闸管故障, 即正常运行。只有一小类: (000)。

第二大类 (010): 只有一只晶闸管故障, 有六小类: VT1 故障 (001), VT2 故障 (010), VT3 故障 (011), VT4 故障 (100), VT5 故障 (101), VT6 故障 (110)。

第三大类 (011): 接到同一相电压的两只晶闸管故障, 有三小类: VT1 和 VT4 故障 (001), VT2 和 VT5 故障 (010), VT3 和 VT6 故障 (011)。

第四大类 (100): 在同一半桥中的两只晶闸管故障, 有六小类: VT1 和 VT3 故障 (001), VT2 和 VT4 故障 (010), VT3 和 VT5 故障 (011), VT4 和 VT6 故障 (100), VT5 和 VT1 故障 (101), VT6 和 VT2 故障 (110)。

第五大类 (101): 交叉两只晶闸管故障, 有六小类: VT1 和 VT2 故障 (001), VT2 和 VT3 故障 (010), VT3 和 VT4 故障 (011), VT4 和 VT5 故障 (100), VT5 和 VT6 故障 (101), VT6 和 VT1 故障 (110)。

这样, 共得了五大类, 22 小类故障。并且对故障进行了编号。每种故障对应着六位编码 $Y_6 Y_5 Y_4 Y_3 Y_2 Y_1$ 。 $Y_6 Y_5 Y_4$ 表示大类, $Y_3 Y_2 Y_1$ 表示所属大类中的小类, 如: 011 010 表示为第三大类中的第二小类故障: VT2 和 VT5 同时开路。对应于每组

特征信号的故障编码作为网络的目标输出样本。如表 1 所示。

将电路针对各种故障进行故障模拟。对故障电路负载电压的一个周期 (20 ms) 采样, 采样时间

为 0.4 ms, 得到 22 组, 每组 51 个数据点的样本, 对它们进行归一化处理以后, 即得到网络的标准输入样本。表 2 是部分标准样本。

表 1 故障分类编号表 (网络目标输出)

Tab 1 Fault classification numbering (the target output of network)

故障分类	大类	一		二		三		四		五												
	小类																					
编号	Y_6	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	
	Y_5	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
	...	1	0	0	0	0	0	0	1	1	1	0	0	0	0	0	1	1	1	1	1	1
	Y_2	0	0	0	0	1	1	1	0	0	0	0	0	1	1	1	0	0	0	1	1	1
	Y_1	0	0	1	1	0	0	1	0	1	1	0	1	1	0	0	1	0	1	1	0	0
		0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0

表 2 标准输入样本

Tab 2 Standard input sample

	X^1	X^2	X^3	X^4	X^5	X^6	...	X^{20}	X^{21}	X^{22}
X_1	0.1464	0.1660	0.1660	0.1660	0.1660	0.0835	...	0.0942	0	0.0942
X_2	0.1452	0.1647	0.1647	0.1647	0.1647	0.1011	...	0.1141	0	0.0728
...
X_{51}	0.1464	0.1660	0.1660	0.1660	0.1660	0.0835	...	0.0942	0	0.0942

表 3 网络训练结果

Tab 3 Result of network training

网络结构	训练样本个数	目标误差	训练步数	训练时间 /s	对结构和初值的敏感度
函数型网络	22	$SSE = 10^{-3}$	3 465	57	中
权值型网络	22	$SSE = 10^{-3}$	6 909	161	高
普通 BP 网络	22	$SSE = 10^{-3}$	4 317	83	中

表 4 网络故障识别结果

Tab 4 Result of network recognition

网络结构	检验样本个数	均匀分布噪声				正态分布噪声 ($\mu=0, \sigma=0.5$)			
		+5% 噪声		+10% 噪声		+5% 噪声		10% 噪声	
		识别个数	识别率	识别个数	识别率	识别个数	识别率	识别个数	识别率
函数型网络	1 000	1 000	100%	981	98.1%	1 000	100%	991	99.1%
权值型网络	1 000	1 000	100%	976	97.6%	1 000	100%	984	98.4%
普通 BP 网络	1 000	934	93.4%	488	48.8%	962	96.2%	618	61.8%

2.2 仿真结果及比较

由于是将采集的 51 点数据作为故障特征信息输入神经网络, 输出要求为 6 位故障编码, 因此, 网络输入节点 $N=51$, 输出节点 $S=6$ 。由于确定隐层神经元个数尚无成熟理论指导, 这里依据经验取第一层节点 $K=25$, 第二隐层节点 $M=18$ 。小波函数选用草帽函数 $(x) = (1 - x^2) \cdot e^{-x^2/2}$ 。输出节点的 s 函数选用对数函数: $(x) = 1/(1 + e^{-x})$ 。网络的初始权值, 伸缩和平移系数均由随机函数 $rands()$ 给出。在带动量项的自适应 BP 算法中, 取允许最大误差率 $er=1.04$, 动量因子常数 $MC_1=0, MC_2=0.95$, 初始学习率 $lr=0.5$, 学习率减少率 $dm=0.7$, 学习率增长率 $im=$

1.05。用 2.1 节中学习样本训练小波网络, 另外也用此样本对文献 [2~5] 中所采用的普通 BP 网络进行训练 (同样, 采用 BP 梯度下降、带动量项和自适应学习率的训练算法)。目标误差为 $SSE = 10^{-3}$ 。训练结果如图 4 及表 3 所示。

对上述训练好的网络采用下面的方法进行仿真测试: 将网络的标准输入样本, 加入不同比例, 不同类型的噪声, 得到网络非训练样本数据, 任意取 1 000 组数据作检验样本, 对网络的故障识别准确性进行测试。这里只要输出 y'_s 满足 $|y'_s - y_s^p| < 0.1$, 就认为得到正确的输出, 识别结果如表 4 所示。

从图 4、表 3 和表 4 不难看出, 在网络训练收敛速度上, 函数型网络略优于普通 BP 网络, 而权值型

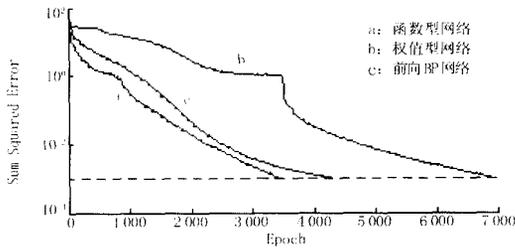


图 4 网络训练误差曲线图

Fig 4 Error curve of network training

网络收敛较慢。在故障识别上,两种小波网络对噪声样本的识别率均远远高于普通 BP 网络。

3 结论

本文针对电力电子电路故障模式识别提出了两种小波神经网络,其均表现出较强的抗噪声能力,能较准确地从含噪声的信号中识别出电路故障。此外,仿真中发现上述网络训练的收敛性对网络的结构和初值的选取都是比较敏感的。下一步,我们将考虑采用遗传算法对网络的权值和结构进行优化。

参考文献:

- [1] 程肇基,徐德洪. 诊断电力电子电路故障的一种新方法—基函数法[J]. 中国电机工程学报, 1989, 9(5): 22-29.
CHENG Zhao-ji, XU De-hong A New Approach to the Fault Diagnosis of Power Electronic Circuits Basic Function Approach[J]. Proceedings of the CSEE, 1989, 9(5): 22-29.
- [2] 苏鹏声,王志强,姜建国. 用人工神经网络诊断电力电子电路主回路故障[J]. 清华大学学报(自然科学版), 1999, 39(3): 19-22
SU Peng-sheng, WANG Zhi-qiang, JIANG Jian-guo. Fault Diagnosis of Power Electronic Circuits Using Artificial Neural Networks[J]. Journal of Tsinghua University, Natural Science, 1999, 39(3): 19-22
- [3] 张选利,蔡金锭,刘庆珍. 人工智能在电力电子电路故

障诊断中的应用[J]. 福州大学学报(自然科学版), 2003, 31(3): 303-307.

ZHANG Xuan-li, CAI Jin-ding, LIU Qing-zhen The Application of Artificial Intelligence on Fault Diagnosis of Power Electronic Circuit[J]. Journal of Fuzhou University, Natural Science, 2003, 31(3): 303-307.

- [4] 马皓,徐德鸿,卞敬明. 基于神经网络的电力电子电路故障诊断[J]. 电力电子技术, 1997, (4): 10-12
MA Hao, XU De-hong, BIAN Jing-ming Fault Diagnosis of Power Electronic Circuits Based on Neural Network [J]. Technology of Power Electronics, 1997, (4): 10-12
- [5] 马皓,徐德鸿. 两种基于神经网络的电力电子电路故障诊断方法比较[J]. 机电工程, 1999, (3): 47-49.
MA Hao, XU De-hong Two Fault Diagnosis Methods Comparison of Power Electronic Circuits Based on Neural Network[J]. MEEM, 1999, (3): 47-49.
- [6] Zhang Q, Benveniste A. Wavelet Networks [J]. IEEE Trans on Neural Net, 1992, 3(11): 889-898
- [7] 陈哲,冯天瑾. 小波神经网络研究进展与展望[J]. 青岛海洋大学学报, 1999, 29(4): 663-668
CHEN Zhe, FENG Tian-jin Research Developments and Prospects of Wavelet Neural Networks[J]. Journal of Ocean University of Qingdao, 1999, 29(4): 663-668
- [8] 唐贤瑛,张友亮. 基于 BP 小波网络的故障模式识别[J]. 计算机工程, 2003, 29(1): 94-95.
TANG Xian-ying, ZHANG You-liang Pattern Recognition for Faults Based on BP Wavelet Network[J]. Computer Engineering, 2003, 29(1): 94-95.

收稿日期: 2004-09-27; 修回日期: 2004-11-29

作者简介:

李微(1981-),男,硕士研究生,研究方向为电力电子与电力传动,神经网络,变结构控制; E-mail: snowmanlee@163.com

谭阳红(1971-),女,博士,副教授,主要从事神经网络、小波及信号处理、故障诊断等方面的科研和教学工作;

彭永进(1938-),男,博士生导师,教授,研究方向为电力电子与电力传动,离散事件动态系统,变结构控制。

Fault pattern recognition of power electronic circuits based on wavelet neural network

LI Wei, TAN Yang-hong, PENG Yong-jin

(College of Electric & Information Engineering, Hunan University, Changsha 410082, China)

Abstract: A fault pattern recognition method of power electronic circuits based on two wavelet neural networks is presented. Two different three-layer wavelet neural networks are constructed for fault pattern recognition of power electronic circuits, and the mathematical model and learning arithmetic are given. Taking three-phase rectifier circuit as an example, the relationship between the output of wavelet neural network and fault component is constructed, the fault recognition of circuits achieved, and the recognition results by two networks compared with that by general BP network. The validity and veracity of two methods are verified by simulation.

Key words: wavelet; neural network; fault pattern recognition; power electronic circuit