

模拟电路故障信号的小波预处理

彭卫韶, 李力争, 胡燕瑜

(中南大学 信息科学与工程学院, 湖南 长沙, 410083)

摘要: 针对模拟电路故障诊断的神经网络存在结构规模较大的问题, 提出一种基于小波-神经网络的模拟电路故障诊断方法。该法采用冲激响应来获取模拟电路的故障信号, 采用小波变换作为模拟电路故障信号的预处理器, 利用 Haar 小波分层次分解提取故障信号特征, 该信号特征经主元分析和数据标称化后, 作为用于故障诊断的神经网络的输入。基于该法故障诊断的基本原理, 对一实例电路进行故障划类、小波函数及故障特征选择, 给出计算故障特征的仿真编程及故障类别的识别方法。该法大大减少用于故障诊断的神经网络的输入数目, 简化它的结构和减少其训练处理的时间。仿真结果表明, 该法可以提高模拟电路故障诊断的效率和辨识故障类别的能力。

关键词: 小波变换; 神经网络; 故障诊断; 模拟电路

中图分类号: TP27

文献标识码: A

文章编号: 1672-7207(2008)03-0584-06

Wavelet preprocessing of analog circuit fault signal

PENG Wei-shao, LI Li-zheng, HU Yan-yu

(School of Information Science and Engineering, Central South University, Changsha 410083, China)

Abstract: Aiming at the problem of larger structure of neural network used for analog circuit fault diagnosis, a fault diagnosis method based on wavelet-neural network for analog circuit was presented. The method uses impulse response to obtain the fault signal, uses wavelet transform as a preprocessor of this fault signal, and uses Haar wavelet decomposition to obtain the feature of the fault signal. Then through principal component analysis and data normalization, the feature of the fault signal was used as the input of a neural network for fault diagnosis. Based on the basic principle of this fault diagnosis method, the fault classification, the selection of the wavelet function and the selection of the fault features for an example circuit were studied, and the fault category identification and a simulation program for computing fault features were also given. This method drastically reduces the number of inputs, simplifies the structure and decreases the training and processing time of the neural network. Simulation result shows that the method will improve the fault diagnosis efficiency and the fault classifying capacity.

Key words: wavelet transform; neural network; fault diagnosis; analog circuit

基于神经网络的故障诊断方法无需知道模拟电路故障的物理模型、元件容差和非线性特性^[1-3]。如在 BP 神经网络的模拟电路故障诊断中, 所有电路故障由惟一的一组特征表示。这些特征与相关的故障类别一

起作为神经网络的输入-输出对, 由 BP 神经网络进行学习和训练, 然后, 将被测试的一组特征输入给 BP 神经网络, 由该 BP 神经网络作为故障分类器来识别故障类型。但这些方法在实际应用中存在神经网络的

收稿日期: 2007-09-25; 修回日期: 2007-12-10

基金项目: 国家自然科学基金资助项目(50575228)

通信作者: 彭卫韶(1970-), 女, 湖南双峰人, 硕士, 高级实验师, 从事电子技术及非线性电路故障诊断研究; 电话: 0731-8836717; E-mail: pws315@mail.csu.edu.cn

输入数目颇多, 结构规模较大, 训练和处理时间长等不足。小波分析是自 1986 年以来在 Y. Meyer, S. Mallat 及 I. Daubechies 等工作的基础上迅速发展起来的一门新兴学科^[4]。由于小波分析具有在时域和频域的良好局部特性和对信号有较强的特征提取功能^[5], 近几年来已得到广泛应用。在此, 本文作者采用小波分析, 将电路故障信号进行分层次分解, 以获得不同频段的信号成分, 取其能反映故障信号特征的低频成分作为模拟电路故障特征, 即将小波变换作为神经网络的预处理器, 这样可大大减少神经网络的输入数目, 从而简化神经网络的结构, 减少它的训练时间, 并提高辨识故障类别的能力。

1 基于小波变换的神经网络故障输入信号的预处理

在实际应用中, 当采用 BP 神经网络对模拟电路进行故障诊断时, 可能会存在对于小规模模拟电路也需构造结构规模大的神经网络^[6]。由于小波分析在时域和频域的良好局部特性和对信号有较强的特征提取功能, 若对故障电路的输出信号(采用冲激响应)先进行小波变换处理, 得到故障特征, 再对这些故障特征进行主元分析(PCA), 而 PCA 是在尽可能多地保持故障特征分类的相关信息的基础上选择使分类误差最小的最优特征作为故障特征矢量, 从而可降低输入空间的维数。然后, 对经 PCA 选择的特征矢量进行数据标称化, 以消除多维矢量数据之间存在相差几个数量级的差别, 这样, 一方面, 使得数据比较小但又比较重要的特征矢量在故障识别时发挥应有作用, 另一方面, 又避免了多维矢量中由于数据差别甚大而形成大的动态范围。最后, 将这些标称化后的特征矢量作为 BP 神经网络的输入。上述方法可使 BP 神经网络具有较少的输入特征数目和较小规模结构, 从而减少 BP 神经网络的训练和处理时间。该方法的处理流程^[7]如图 1 所示。这里着重论述小波变换对电路故障信号的预处理。

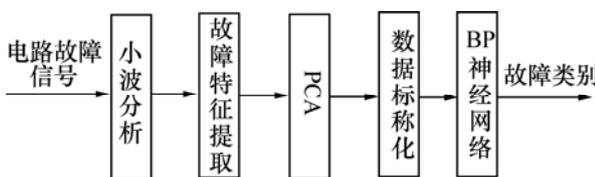


图 1 基于小波-神经网络的故障诊断流程图

Fig.1 Flow chart of fault diagnosis based on wavelet-BPNN

1.1 故障信号的小波分解及特征提取

小波分析是一种优于傅里叶变换的分析方法, 它在时域和频域同时具有良好的局部化性质, 能够集中注意数据中令人感兴趣的局部。对于任意信号 $f(t)$, 其小波变换定义^[1, 8-9]为:

$$W_f(a, b) = \frac{1}{\sqrt{a}} \int f(t) \psi^* \left(\frac{t-b}{a} \right) dt = \langle f(t), \psi_{a,b}(t) \rangle \quad (1)$$

式中: ψ 为小波母函数; a 为尺度参数; b 为时间中心参数。

$W_f(a,b)$ 即为信号的小波分解系数, 它表征了信号 $f(t)$ 的特征。

变换式(1)一般只能通过计算机进行近似数值计算。采用离散形式进行小波分析, 可用矩形法、梯形法和梅林变换等算法实现。为达到较高的精度和使计算简单, 一般采用梯形法作近似数值积分运算, 取 $t = n \cdot \Delta T$, $b = K \cdot \Delta T$, 则计算公式^[10]为:

$$W_f(a, k) = \frac{\Delta T}{2\sqrt{a}} \sum_n \left[f(n) \psi \left(\frac{n-k}{a} \right) + f(n+1) \psi \left(\frac{n+1-k}{a} \right) \right] \quad (2)$$

式中: ΔT 为采样间隔, 并假定 $a=2^i$ ($i=1, 2, \dots, n$)。

对于每一个给定的 $a=2^i$, 依次计算 k 不同时之值, 可得到一组小波变换的系数(即信号的小波分解特征)。

Mallat 根据多分辨率理论, 提出了小波分解与重构的快速算法, 称为 Mallat 算法。Mallat 算法的小波分解可以理解为把原始信号分解为 1 个低频逼近信号和 1 个高频细节信号, 它们分别对应于大尺度参数(低频率)和小尺度参数(高频率)的信号成分, 信号的小波分层次分解过程^[11]如图 2 所示, 图中“ $\downarrow 2$ ”表示二抽样。

分解公式为:

$$c(i, n) = \sum_l h(2n-l)c(i-1, n) \quad (3)$$

$$d(i, n) = \sum_l g(2n-l)c(i-1, n) \quad (4)$$

式中: $c(i, n)$ 和 $d(i, n)$ 分别为尺度 i 的离散小波低频逼近和高频细节系数; $h(n)$ 和 $g(n)$ 分别为一对共轭镜像滤波器 H(低通)和 G(高通)的脉冲响应。

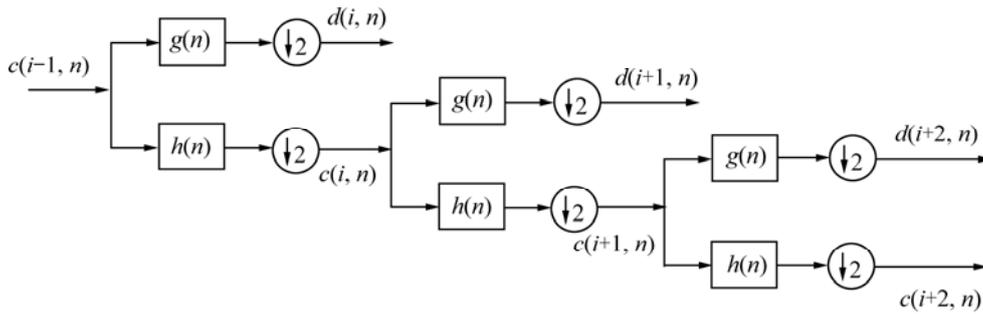


图 2 小波变换对信号的分层次分解过程

Fig.2 Process of level decomposition of signal by wavelet transform

由于低频部分代表信号的近似，高频部分代表信号的细节，所以，小波分解可看成是信号形成一族分层组织的低频和低频成分的产生过程。

从信号的 Mallat 分解算法^[12]可知，信号序列每分解一层，离散逼近和细节系数将各自减半，即第 i 层所得近似和细节成分中的数据点的数目与第 $(i-1)$ 层的数据点的对应数目相比，减少为 $1/2$ 。若将离散逼近系数和(或)细节系数作为 BP 神经网络的输入，则可使 BP 神经网络输入数目减少。由于所诊断的模拟电路故障信号的主要特征可在近似系数中获得，所以，将小波分解至一定层次，只需选择每一层次低频逼近的第一个小波系数作为故障特征，并输入 BP 神经网络便可进行故障诊断。

1.2 小波函数的选择及特性

小波变换的本质是测量被分析信号波形的局部相似程度，根据被分析的信号特点，选择波形合适的小波对模拟故障电路输出进行预处理以提取理想故障特征是关键^[13]。由于 Haar 小波函数的不连续特性使之具有紧支撑和零调和性，Haar 小波非常适合于从具有窄宽度和快速变化的信号中提取特征，这符合本文故障电路冲激响应信号的特点(本文的故障信号采用冲激响应)，且计算简单，故在本诊断方法中被采用。Haar 函数的定义为：

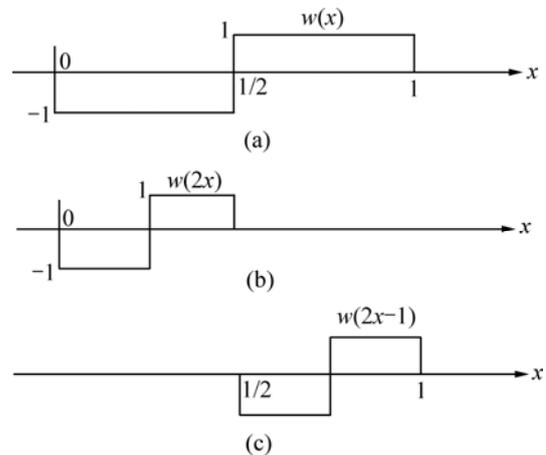
$$w(x) = \begin{cases} -1, & 0 \leq x < 1/2; \\ 1, & 1/2 \leq x < 1. \end{cases} \quad (5)$$

其自变量 x 的定义域为 $[0, 1]$ 。Haar 函数波形如图 3 所示。对于任意一个信号 $f(x)$ 可表示成不同尺度的 Haar 小波之和：

$$f(x) = a_0 + a_1 w(x) + a_2 w(2x) + a_3 w(2x-1) + a_4 w(4x) + a_5 w(4x-1) + \dots = a_0 + \sum_{j=0}^{\infty} \sum_{k=0}^{2^j-1} a_{2^j+k} w(w^j x - k) \quad (6)$$

式中： $f(x)$ 为有限长度的信号， $0 \leq x < 1$ ； a_i 为小波变换系数； $w(x)$ 为小波函数。利用 Haar 小波具有任意两个不同尺度的小波之间两两都有正交性的性质，可得到式(6)中的系数 $a_i (i=0, 1, 2, \dots)$ 的计算公式：

$$a_{2^j+k} = 2^j \int_0^1 w^2(2^j x - k) dx \quad (7)$$



(a) $w(x)$ 波形；(b) $w(2x)$ 波形；(c) $w(2x-1)$ 波形

图 3 Haar 小波函数波形图

Fig.3 Diagram of Haar wavelet function

2 MATLAB 小波分解仿真程序

离散二进制小波分解的梯形近似数值积分运算式(2)虽然给出了计算小波系数的工具，但可以直接利用

MATLAB 所提供的 Haar 小波分解仿真程序计算和提取模拟电路故障信号(冲激响应)的低频逼近系数 $c(i, n)$, 并作为故障特征。提取尺度参数 $i=1, 2, 3$ 层次的 Haar 小波分解低频逼近系数的编程为:

```
[c, 1]wavedec(S, 3, "HAAR"); %用 Haar 小波对故障信号 S 进行 3 尺度分解。
```

```
Ca1=appcoef(c, 1, "HAAR", 1); %从小波分解结构[c, 1]中提取尺度参数  $i=1$  的低频逼近系数  $c(1, n)$ 。
```

```
Ca2=appcoef(c, 1, "HAAR", 2); %从小波分解结构[c, 1]中提取尺度参数  $i=2$  的低频逼近系数  $c(2, n)$ 。
```

```
Ca3=appcoef(c, 1, "HAAR", 3); %从小波分解结构[c, 1]中提取尺度参数  $i=3$  的低频逼近系数  $c(3, n)$ 。
```

Ca1, Ca2 和 Ca3 分别为尺度参数 $i=1, 2, 3$ 的低频逼近系数。

3 实例电路的故障分类与故障信号(冲激响应)的产生

现以图 4 所示的带通滤波电路作为实例故障诊断电路。图中电路成分 R_3, C_2, R_2 及 C_1 只在容差范围(电阻与电容的容差均假定为 $\pm 10\%$)内改变的情况属于无故障类(NF)。现只研究电路单一成分故障, 即此 4 个成分中的任意 1 个参数高于或低于其额定值 50%, 而其他 3 个成分均在容差范围内变化。这样, 电路有 9 种可能不同的工作类别, 即 NF, $C_1\uparrow, C_1\downarrow, C_2\uparrow, C_2\downarrow, R_2\uparrow, R_2\downarrow, R_3\uparrow$ 和 $R_3\downarrow$, 其中: 符号“ \uparrow ”和“ \downarrow ”分别表示增高和降低额定值的 50%以上。对 9 种工作类别, 滤波电路输出的冲激响应以同样的方式馈送至小波变换预处理器, 通过 MATLAB 提供的 Haar 小波分解仿真程序对故障冲激响应提取故障特征, 这些故障特征与对应的故障类别一起作为输入—输出对输送给 BP 神经网络进行训练, 建立期望的输入—输出关系^[14]。

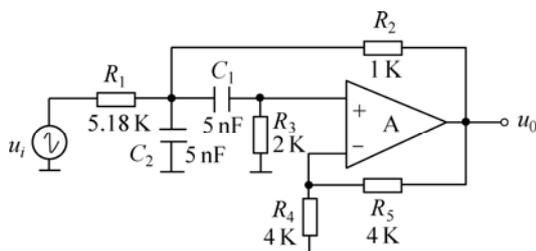


图 4 带通滤波电路

Fig.4 Circuit of band-pass filter

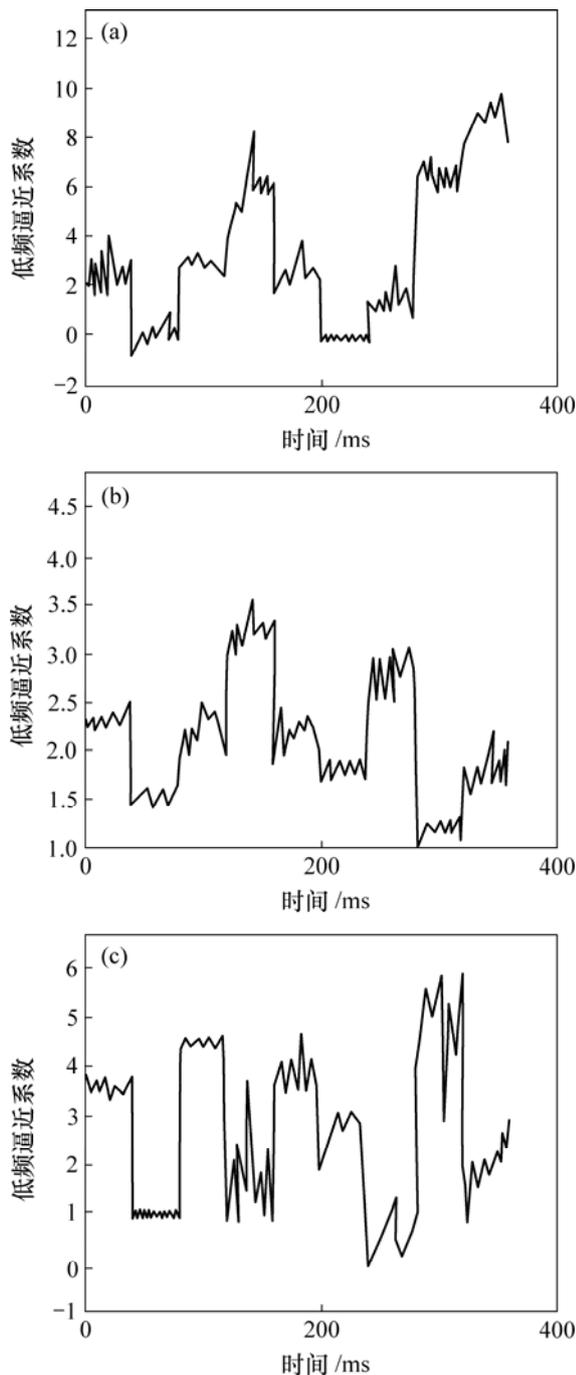
为获得故障电路 9 种不同工作状态的故障信号, 可通过一个窄脉冲来近似产生冲激响应, 该窄脉冲的宽度 T 远小于滤波电路带宽的倒数。在所有的 SPICE 仿真中, 均取一个幅度为 6 V、脉冲宽度 $T=10 \mu\text{s}$ 的单脉冲输入给滤波电路, 获得不同的冲激响应, 即故障信号。仿真结果表明, 应用该窄脉冲产生的冲激响应对故障进行分类是完全满足要求的。

4 故障特征的选择与故障类别辨识

原始信号(故障电路的冲激响应)经 Mallat 算法分解为“逼近信号”系数 $c(i, n)$ 和“细节信号”系数 $d(i, n)$, 这些系数分别反映了信号的低频和高频内容, 低频内容一般给出了信号在大时间范围内的基本结构, 高频内容提供了信号在局部时间内的细节特性。两者均可以表示故障特征, 这里选择与滤波电路相关的 1~3 层的“低频逼近”的第一个系数作为故障特征, 并绘出它们的特征曲线, 如图 5 所示, 运用这些特征曲线就可以对故障类别进行辨识^[15]。

对滤波电路的无故障(NF)和 8 种单一故障类别的每一个类别连续产生 40 个相同的冲激响应, 后面产生的冲击响应与前面的相互重叠, 由 MATLAB 所提供的 Haar 小波分解仿真程序可得到 40 个“低频逼近”第一个系数, 与这些冲激响应相联系的“低频逼近”系数如图 5 所示。图 5(a)~(c)分别对应尺度参数 $i=1, 2$ 和 3 的第一、第二及第三层次的小波分解的“低频逼近”系数(故障特征曲线), 图中的纵坐标相应于“低频逼近”第一个系数值的标尺(无量纲)。将横坐标范围从 0~360 分成 9 个间隔, 每个间隔的尺度为 40(它对应某一故障类别的 40 个“低频逼近”系数点)的时间间隔, 绘图中的间隔彼此用垂直线隔开, 每一绘图中的 9 个间隔分别代表电路的 NF 和 8 种故障类别, 其在横轴排列的秩序从 0~360 依次为 $C_1\uparrow, C_1\downarrow, C_2\uparrow, C_2\downarrow, \text{NF}, R_2\uparrow, R_2\downarrow, R_3\uparrow$ 和 $R_3\downarrow$ 。

根据故障特征曲线对故障类别进行辨识。选择同一层次中彼此差异大的特征曲线构成故障特征矢量, 经 PCA 及数据标称化后作为故障特征样本送入 BP 神经网络, 能准确地辨识它们所对应的故障类别。而同一层次中彼此差异不大的特征曲线, 由于容易混淆而导致故障辨识错误, 因此, 不宜选用。例如从图 5(a)(层次 $i=1$)所示的特征曲线可以辨识 $C_2\downarrow, R_2\uparrow$ 和 $R_3\downarrow$; 由图 5(b)(层次 $i=2$)所示的特征曲线可辨识



(a) 第一层($i=1$); (b) 第二层($i=2$); (c) 第三层($i=3$)

图 5 图 4 所示电路 1~3 层 ($i=1\sim 3$) 的第一个低频逼近系数图

Fig.5 Plot of the first element of levels 1~3($i=1\sim 3$) approximation coefficients for the circuit shown in Fig.4

$C_2\downarrow$, $R_2\downarrow$ 和 $R_3\uparrow$; 由图 5(c)(层次 $i=3$)所示的特征曲线可辨识 $C_1\downarrow$, $C_2\uparrow$ 和 NF 等故障类别。如果同一层次的特征曲线彼此差异都不明显, 则可以增加分解层次, 例如 $i=4, 5, \dots$, 以求获得在同一层次中彼此差异大

的特征曲线。必须指出, 一般只选择同一层次中差异最大的一些特征值曲线构成故障特征矢量, 这样, 既可以提高 BP 神经网络故障辨识的准确性, 又可以减少 BP 神经网络的输入数目, 简化其结构规模和加快训练处理时间。

5 结 论

a. 采用 Mallat 算法对模拟电路各原始故障信号进行小波变换, 只要适当增加信号的小波分解层次, 就能选出数值独异的小波低频逼近系数。用这些系数表征故障特征, 可以剔除故障信号的冗余信息, 从而提高故障诊断效率。

b. 采用小波变换作为 BP 神经网络输入的预处理器, 使 BP 神经网络的结构得到简化。与无小波预处理器的同一滤波电路的 BP 神经网络故障诊断系统相比较, 系统由 49 个输入、三层的 BP 神经网络减少为 3 个输入、二层的 BP 神经网络, 神经元由 20 个减为 8 个, 可调参数由 700 个降为 40 个。

参考文献:

- [1] Spina R, Upadhyaya S. Linear circuit fault diagnosis using neuromorphic analysis[J]. IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing, 1997, 44(3): 188-196.
- [2] 袁修贵, 王 军, 黄修建, 等. 基于小波变换的一种图像增强去噪算法[J]. 中南大学学报: 自然科学版, 2005, 36(2): 298-301.
YUAN Xiu-gui, WANG Jun, HUANG Xiu-jian, et al. An improved algorithm of image de-noise and enhancement using wavelet transform[J]. Journal of Central South University: Science and Technology, 2005, 36(2): 298-301.
- [3] Sorsa T, Koivo H N, Koivisto H. Neural network in process fault diagnosis[J]. IEEE Transactions on Systems Man and Cybernetics, 1991, 21(4): 815-825.
- [4] 杨福生. 小波变换的工程分析与应用[M]. 北京: 科学出版社, 2000.
YANG Fu-sheng. Engineering analysis and application of wavelet transform[M]. Beijing: Science Press, 2000.
- [5] Daubechies I. The wavelet transform, time-frequency localization and signal analysis[J]. IEEE Transactions on Information Theory, 1990, 36(5): 961-1005.
- [6] Mallat S G. A theory of multiresolution signal decomposition:

- The wavelet representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(7): 674-693.
- [7] 周开利, 康耀红. 神经网络模型及其 MATLAB 仿真程序设计[M]. 北京: 清华大学出版社, 2004.
ZHOU Kai-li, KANG Yao-hong. Neural network model and its MATLAB simulation program design[M]. Beijing: Tsinghua University Press, 2004.
- [8] HE Yi-gang, LUO Xiang-jue, QIU Guan-yuan. A neural-based nonlinear L_1 -norm optimization algorithm for diagnosis of networks[J]. Journal of Electronics, 1998, 15(4): 365-371.
- [9] 王 承, 陈光福, 谢永乐. 基于小波-神经网络的模拟电路 I_{DDT} 故障诊断[J]. 仪器仪表学报, 2005, 26(11): 1106-1108.
WANG Cheng, CHEN Guang-ju, XIE Yong-le. Fault diagnosis in analog circuits I_{DDT} based on wavelet transform and neural networks[J]. Chinese Journal of Scientific Instrument, 2005, 26(11): 1106-1108.
- [10] 黄同成, 丁友东. 基于多小波神经网络簇轮廓伸展的手写体数字识别[J]. 中南大学学报: 自然科学版, 2006, 37(2): 356-360
HUANG Tong-cheng, DING You-dong. Handwritten numeral recognition based on contour expanding of multi-wavelet neural network clusters[J]. Journal of Central South University: Science and Technology, 2006, 37(2): 356-360.
- [11] 魏 平, 李均利, 陈 刚, 等. 基于小波分解的神经网络 MCP 预测方法及应用[J]. 电力系统自动化, 2004, 28(11): 17-21.
WEI Ping, LI Jun-li, CHEN Gang, et al. Forecasting MCP using a wavelet-improved neural network method[J]. Automation of Electric Power Systems, 2004, 28(11): 17-21.
- [12] 胡昌华, 许化龙. 控制系统故障诊断与容错技术的分析和设计[M]. 北京: 国防工业出版社, 2000.
HU Chang-hua, XU Hua-long. Analysis and design of fault design of control system and fault tolerance technology[M]. Beijing: National Defence Industry Press, 2000.
- [13] 杨 波, 赵遵康, 陈允平, 等. 基于小波变换的边际电价神经网络预测新模型[J]. 电力系统自动化, 2007, 31(12): 40-44.
YANG Bo, ZHAO Zun-lian, CHEN Yun-ping, et al. A novel MCP forecasting model based on wavelet transformation and neural network ensemble in day-ahead electricity market[J]. Automation of Electric Power Systems, 2007, 31(12): 40-44.
- [14] 王 承, 陈光福, 谢永乐. 小波-神经网络在模拟电路故障诊断中的应用[J]. 系统仿真学报, 2007, 17(8): 1936-1938.
WANG Cheng, CHEN Guang-ju, XIE Yong-le. Applying wavelet transform and neural networks to fault diagnosis in analog circuits[J]. Journal of System Simulation, 2007, 17(8): 1936-1938.
- [15] 谢 宏, 何怡刚, 吴 杰. 基于小波-神经网络模拟电路故障诊断方法的研究[J]. 仪器仪表学报, 2004, 25(5): 672-674.
XIE Hong, HE Yi-gang, WU Jie. Research on analog circuit fault diagnostic method based on wavelet-neural network[J]. Chinese Journal of Scientific Instrument, 2004, 25(5): 672-674.