

运用GA-BP神经网络研究时间序列的预测

黄建国, 罗航, 王厚军, 龙兵

(电子科技大学自动化工程学院 成都 610054)

【摘要】神经网络能以任意精度逼近非线性函数,以神经网络为基础的时间序列预测模型能很好地反映信息的非线性发展趋势。该文在分析传统BP网络缺点的基础上,用具有良好全局搜索能力的遗传算法来改进神经网络。详细讨论了GA算法的优化神经网络初始权值和阈值的思想和理论。在阐述预测方法同时,用具体例证分析了GA-BP网络预测的性能和特点。结果表明,基于GA-BP神经网络在预测精度和适应性方面高于传统的BP神经网络。

关键词 基因链; GA-BP神经网络; 优化; 预测; 训练

中图分类号 TP273

文献标识码 A

doi:10.3969/j.issn.1001-0548.2009.05.028

Prediction of Time Sequence Based on GA-BP Neural Net

HUANG Jian-guo, LUO Hang, WANG Hou-jun, and LONG Bing

(School of Automation Engineering, University of Electronic Science and Technology of China Chengdu 610054)

Abstract Neural networks have the capability of approaching nonlinear function with any accuracy. Time-serial prediction model can perfectly show the nonlinear tendency of information. In this paper, the genetic algorithm (GA) with global search capability is adopted to improve traditional back propagation (BP) neural networks, based on analyzing defect of BP neural networks. At the same time, the theory of optimizing initial weights and threshold of neural networks by means of GA method is discussed in detail. In the course of explaining prediction method, two examples are taken to analyze GA-BP neural networks prediction performance and characteristics. The result of prediction shows that the prediction accuracy and adaptability of GA-BP neural networks was better than that of traditional BP neural networks.

Key words chain gene; GA-BP neural net; optimization; prediction; training

由于任何时间序列都可以看作一个由非线性关系确定的输入输出系统,时间序列预测的建模本质是一个非线性参数拟合过程。神经网络可用于许多非参数、非线性的分类和预测问题^[1-3]。采取神经网络对时间序列预测不需要事先对序列的特征做假设,也不需要系统建立精确的输入和输出规则,它是通过自学习过程,基于输入集和期望模式而训练的一种非线性映射关系^[4]。根据Kolmogorov定理,EBP(error back propagation)神经网络可以任意精度逼近任何有理函数。即一个3层的EBP网络可以完成任意的 m 维到 n 维的映射^[5]。

本文的主要目的是将BP网络和GA算法结合起来形成GA-BP网络,对时间序列进行训练和预测。这是因为:(1)单纯BP网络的每个节点和权值都会影响输出,它的适应过程和全局逼近过程比较耗时,因而网络的收敛速度慢;同时BP网络是属于梯度下

降的非凸问题,容易陷入局部极小值,导致错误的工作模式;再者,隐含层的数目及其单元的选取尚无理论上的指导,因而BP网络常常具有很大的冗余性^[5]。(2)遗传算法GA是基于生物进化原理的一种具有鲁棒性的自适应优化方法。该方法以样本适应度函数为基础,对初始群体进行选择、交叉和变异操作来指导学习并确定搜索方向。由于采用种群的方式组织搜索,所以它可以在全局解空间的多个区域内采用随机方法寻求最优解,因此特别适合大规模并行处理^[6]。

考虑BP网络存在的缺陷和GA算法的优势,将两者结合起来进行训练和预测是一种提高预测精度的策略,其主要技术在于:初始给定神经网络,运用GA算法来优化神经网络的初始权值和阈值,当算法达到一定的收敛要求后,再用神经网络进行二次训练,以此来避免局部最优,达到提高网络训练精度

收稿日期: 2009-05-05

基金项目: 国防基础科研项目(A1420061264); 部级预研基金(9140A17030308DZ02)

作者简介: 黄建国(1962-),男,博士,教授,主要从事故障诊断和预测、系统可靠性方面的研究。

和速度的目的。

1 BP神经网络的训练和预测原理

1.1 网络训练的基本思想

一个3层BP网络结构如图1所示,其学习过程由两部分组成:正向传播与反向传播。正向传播让输入信息在相应权值、阈值和激活函数的作用下传递到输出层,当输出的结果和期望值的误差大于给定精度时,则将误差反向传播。在误差返回过程中,网络修正各层的权值和阈值。如此反复迭代,最后使传递信号的误差达到允许精度。

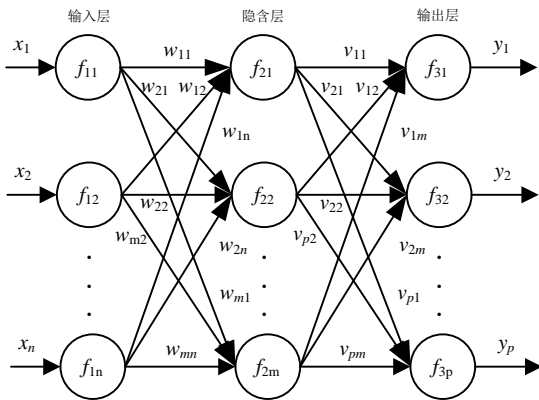


图1 3层BP网络的结构

在网络训练中,正向传播过程的隐层(或输出层)的表述为:

$$o_{kj} = f_j \left(\sum_i a_{ji} o_{ki} + \theta_j \right) \quad (1)$$

式中 f_j 表示第 j 个激活函数,一般为S型(Sigmoid)的函数; a_{ji} (代表 w_{ji} 或 v_{ji}) 表示前一层的第 i 个神经元对当前层的第 j 个神经元的权值; o_{ki} 表示第 k 个样本在前一层的第 i 个神经元上的信息输出; θ_j 表示当前层的第 j 个神经元的阈值。相应地, o_{kj} 表示第 k 个样本在当前层的第 j 个神经元上的信息输出。

当正向传播输出的结果不能满足精度时,则网络从输出层开始逐层反向传递误差。输出层的训练误差表示为:

$$\delta_{kj} = o_{kj} (1 - o_{kj}) (t_{kj} - o_{kj}) \quad (2)$$

式中 t_{kj} 表示第 k 个样本在第 j 个输出单元上的目标值。隐含层的训练误差表示为:

$$\delta_{kj} = o_{kj} (1 - o_{kj}) \sum_m \delta_{km} w_{mj} \quad (3)$$

在上述训练误差的作用下,各权值修正为:

$$w_{ji}(t+1) = w_{ji}(t) + \eta \delta_{kj} o_{ki} + \alpha [w_{ji}(t) - w_{ji}(t-1)] \quad (4)$$

各阈值的修正为:

$$\theta_j(t+1) = \theta_j(t) + \eta \delta_{kj} + \alpha [\theta_j(t) - \theta_j(t-1)] \quad (5)$$

式中 η 称为学习速率,是按梯度搜索的步长,在学习中,只要网络不振荡,则 η 尽量取较大值; α 是为了消除网络振荡而引入的“势态因子”,它通过作用过去权重(阈值)的变化来影响目前权重(阈值)的变化。

当给定输入样本和期望输出后,对每个输入样本重复进行式(2)~式(5)的迭代,当所有样本都训练完毕后,判断指标函数是否满足精度,否则重新训练,直到满足精度为止。至此,网络训练完毕。

1.2 网络预测的基本思想

本质上讲,网络训练的目的在于利用其结构(包括各个神经元及相应权值和阈值)对各种模式进行非线性学习,众多学习信息存储在各个权值和阈值中。只要训练样本可观,则网络存储的信息就越充分,分辨模式的能力就越强。事实上,基于神经网络的时间序列预测正是在训练过去样本的过程中,学习并记忆了序列的发展模式,因而能够预测序列将来的行为。

2 遗传算法优化神经网络的原理

因为网络中存在非线性隐含单元,即使网络在指标曲面上进行梯度下降,却并不一定能保证获得全局极小值。由于网络的指标函数是所有权值和阈值的多元函数,将GA算法和BP网络结合,实际上是利用种群搜索方式对给定网络的权值、阈值进行最优配置,目的是寻找最容易获得全局最优的网络参数,从而改善BP网络过分依赖梯度信息,实现误差全局最小的最大可能性。

2.1 用GA算法优化神经网络的关键过程

用GA算法优化神经网络的连接权和阈值过程有如下3个主要过程:(1)基因的表述(也就是确定权值、阈值的编码)。(2)个体适应度的估计。(3)运用进化操作算子(包括选择,交叉和变异)。在上述3个步骤的基础上算法反复迭代寻优,直到满足条件。

2.1.1 编码

首先建立BP神经网络,将网络的所有权值和阈值(包括输入层到隐层的权阵、隐层到输出层的权阵、隐层阈值和输出层阈值)作为一组有序染色体,依据权值和阈值的数目,用相应维数的实数变量表示。直接采用实数编码是因为:(1)群体中模式的数目仅与群体大小和染色体长度有关。(2)它是连续参数优化问题直接的自然描述,不存在十进制和二进制之间的编码和解码过程。(3)可以提高运算的精度和计算速度,降低计算的复杂性,提高运算效率^[7-10]。

经过编码后的基因为:

$$\mathbf{X} = [w_{11}, w_{12}, \dots, w_{mn}, v_{11}, v_{12}, \dots, v_{pm}, \theta_1, \theta_2, \dots, \theta_m, t_1, t_2, \dots, t_p] \quad (6)$$

2.1.2 适应度

在遗传算法的进化过程中, 对染色体的评价是由适应度函数来完成的, 适应度函数值的计算非常重要, 它是选择运算的依据。遗传算法的搜索目标是获取所有进化代中使网络的误差平方和最小的网络权值和阈值, 而遗传算法是朝着使适应度函数值增大的方向进化^[11]。根据每个个体(权值和阈值)所对应的神经网络计算出BP网络的误差平方和, 适应度函数采用网络误差平方和的倒数:

$$E(\mathbf{X}_i) = \frac{1}{2l} \sum_{k=1}^l \sum_{j=1}^p (d_{kj}^i - o_{kj}^i)^2 \quad (7)$$

$$f(\mathbf{X}_i) = E^{-1}(\mathbf{X}_i) \quad (8)$$

式中 o_{kj}^i 表示第 i 个个体(染色体串)(即权值和阈值的有序向量)作用下, 第 k 个训练样本在第 j 个输出节点的输出值; d_{kj}^i 为期望的输出值; l 为训练样本个数; p 为输出层的神经元的个数, $i=1,2,\dots,N$ (N 为种群规模)。显然, $f(\mathbf{X}_i)$ 表示第 i 个基因链的适应度。

2.1.3 进化操作

(1) 基因选择: 根据式(8), 可得群体中每个个体的适应值。将其大小按降序排列, 然后采用适应度比例选择法(轮盘赌选择)得到其在子代个体中出现的概率, 父代进化通过这种方式得到选择并再生。

(2) 基因交叉: 使用交叉算子能够使算法从全局的角度寻找到较好的个体编码结构。假设要参与交叉操作的两个基因链分别为 \mathbf{X}_i 和 \mathbf{X}_j (\mathbf{X}_i 的适应度大于 \mathbf{X}_j 的适应度), 链上对应位置的染色体分别为 x_i 和 x_j , 定义如下两个中间变量:

$$\Delta_i^1 = \begin{cases} \min \left\{ x_i + \frac{1+p_c}{2}(x_i - x_j), x^{\max} \right\} & x_i \geq x_j \\ \max \left\{ x_i + \frac{1+p_c}{2}(x_i - x_j), x^{\min} \right\} & x_i < x_j \end{cases} \quad (9)$$

$$\Delta_j^1 = \begin{cases} \max \left\{ x_j + \frac{1+p_c}{2}(x_j - x_i), x^{\min} \right\} & x_i \geq x_j \\ \max \left\{ x_j + \frac{1+p_c}{2}(x_j - x_i), x^{\max} \right\} & x_i < x_j \end{cases} \quad (10)$$

式中 x^{\min} 和 x^{\max} 分别为 x_i (x_j) 取值的下限和上限, 交叉后所产生的新个体 y_i 和 y_j 由下式确定^[12-13]:

$$y_i = \frac{1+p_c}{2} \Delta_i^1 + \frac{1-p_c}{2} \Delta_j^1 \quad (11)$$

$$y_j = \alpha x_i + (1-\alpha)x_j \quad (12)$$

式中 α 为[0,1]之间的随机数; p_c 为交叉概率, 由下式确定^[14]:

$$p_c = \begin{cases} k_1 \frac{f_{\max} - f_b}{f_{\max} - f_{\text{avg}}} & f_b \geq f_{\text{avg}} \\ k_2 & f_b < f_{\text{avg}} \end{cases} \quad (13)$$

式中 k_1 和 k_2 是[0,1]中的常数; f_b 表示要交叉的两个个体中适应度较大的一个; f_{\max} 是种群中的最大适应度; f_{avg} 表示种群的平均适应度。这种自适应交叉概率限制了交叉概率的范围, 使其适应度较小时有恒定的交叉概率, 适应度较大时, 则减小交叉的概率。式(11)和式(12)所述的交叉运算保证了子代中的一个在其父代所在的区域之间搜索, 另一个向适应度高的父代个体的方向搜索新的领域。这种方式突出了训练的效率, 保证了搜索的多样性。

(3) 基因变异: 为了使个体从局部角度更加逼近最优解, 并使算法在接近最优解邻域时能加速收敛, 采用某一均匀分布的随机数来替换原有的基因, 使个体在搜索空间内自由移动, 即在父代个体中随机选择变异点 k , 则变异点新基因值为:

$$\tilde{\mathbf{X}}_k = \mathbf{X}_{\min} + \beta \cdot (\mathbf{X}_{\max} - \mathbf{X}_{\min}) \quad (14)$$

式中 \mathbf{X}_{\min} 和 \mathbf{X}_{\max} 分别为初始个体目标变量的最小值与最大值; β 为[0, 1]内均匀分布的随机数。如果说交叉算子从全局上寻找到较为优秀的个体, 则变异算子在搜索空间中的细节上来调整并优化编码结构。采用基因变异能够提高算法的局部搜索能力并维持群体的多样性。

2.2 GA-BP网络优化的流程

综上所述, GA-BP建模的关键是确定BP神经网络的结构层数和每层的神经元数、由权值和阈值形成基因链、种群规模 N 、交叉概率 p_c 的两个常数 k_1 和 k_2 以及迭代精度 s_1 和 s_2 。当迭代满足既定的终止条件时, 则将最优适应度个体的值解码, 为下一步的BP网络的再训练提供初始权值和阈值(分别为 \mathbf{W} 、 \mathbf{V} 、 $\boldsymbol{\theta}$ 和 \mathbf{T})。其流程如图2所示。

在具体训练时, 样本为 $\mathbf{S}_{u \times n}$ 矩阵, 目标为 $\mathbf{G}_{u \times p}$ 矩阵。显然, 输入层节点数为 n , 输出层节点数为 p , 隐含层节点数由经验公式 $m = \sqrt{np}$ 确定。则个体的编码长度(染色体) $L = nm + mp + m + p$ 。

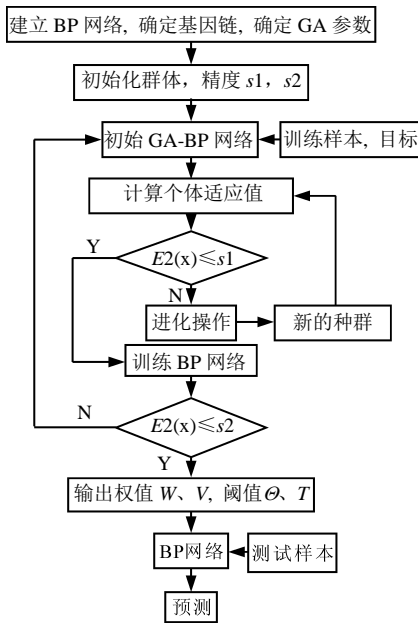


图2 基于GA-BP神经网络的预测流程

3 两个基于GA-BP网络的预测实例

3.1 训练和预测方法

以南方某缺电城市2004年7月10~7月20日整点有功负荷值为研究对象^[15]。每天每隔2 h测量有功负荷值(每天测试12个数据),同时对7月11~21日的3个主要影响因子(温度、天气、星期)的状态加以量化,如表1所示。每天的实际影响因子是三种情况的不同组合。用前日测试数据(归一化后)和当日3个影响因子一起构成的15个数据作为训练样本,训练目标为当日的测试数据。当训练成功后,用7月20日的测试数据及7月21日的影响因子来预测21日的有功负荷情况。

表1 有功负荷的影响因子

影响因子	量化值
晴、温度35°C以上、周六至周日	1.0
阴、温度30~35°C、周五	0.5
雨、温度30°C以下、周一至周四	0

年平均太阳黑子活动数据是被公认为最具有代表性的非线性、非高斯分布、非平稳的时间序列,是用于比较和评判统计学模型和预测方法的典型数据^[16]。以1700年以来的太阳黑子年平均变化的部分数据(归一化)为研究对象。对时间序列进行移位加窗(窗口的长度为季节长度,用方差分析方法确定^[17]),根据已确定的季节长度 k ,从序列的第一个数据开始依次取 k 个数据,作为训练样本,第 $k+1$ 个数据作为训练目标。然后将时间窗口向后移动一位,从序列的第2个数据开始用相同的方法选取训练样本

和目标,直到选定足够多的训练样本和目标。用训练好的GA-BP神经网络依次对移动窗口内的数据进行预测。两个实验的网络结构和参数如表2所示。

表2 GA-BP网络的结构和训练参数

训练参数	样本容量	目标容量	隐层节点	基因长度	种群规模
有功负荷	$S_{10 \times 15}$	$G_{10 \times 12}$	14	416	50
太阳黑子	$S_{30 \times 10}$	$S_{30 \times 1}$	4	129	50
训练参数	遗传代数	测试容量	精度 $s1, s2$	学习速率	最大迭代
有功负荷	100	$M_{1 \times 15}$	0.001	0.1	5 000
太阳黑子	100	$M_{120 \times 10}$	0.001	0.1	5 000

3.2 预测结果

表3列出了2004年7月21日有功负荷预测的6次MSE及所耗的时间,图3和图4分别列出了第2次实验过程中个体(权值和阈值编码成的基因链)适应度值随代数变化(追踪)的情况和预测的结果。

表3 有功负荷预测的MSE和时间

次数		1	2	3
MSE	GA-BP	0.027 8	0.022 1	0.025 9
	BP	0.041 8	0.0500	0.050 2
t/s	GA-BP	6.922 0	4.1442	2.999 3
	BP	0.309 9	2.084 0	0.296 0
次数		4	5	6
MSE	GA-BP	0.026 9	0.026 2	0.036 4
	BP	0.039 8	0.057 0	0.043 0
t/s	GA-BP	3.228 8	3.895 3	4.937 3
	BP	0.476 2	0.268 9	0.032 1






图3 预测有功负荷的GA-BP基因链追踪



a. 有功负荷预测结果



b. 预测的相对误差

图4 有功负荷预测的结果

表4列出了6次预测1730~1849年太阳黑子的MSE及所耗的时间,图5和图6分别是第1次基因个体的适应度追踪情况及预测结果。

表4 太阳黑子预测的MSE和时间

次数		1	2	3
MSE	GA-BP	0.114 3	0.195 0	0.126 9
	BP	0.125 8	0.327 5	0.111 8
t/s	GA-BP	3.229 9	1.961 8	1.811 8
	BP	0.897 7	0.094 4	0.286 1

次数		4	5	6
MSE	GA-BP	0.149 4	0.188 3	0.132 9
	BP	0.316 8	0.364 0	0.362 2
t/s	GA-BP	2.372 3	2.175 6	1.844 5
	BP	0.022 1	0.017 3	0.004 7




图5 预测太阳黑子的GA-BP基因链追踪

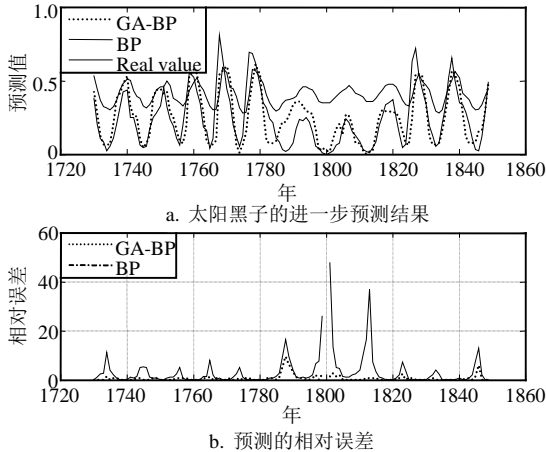


图6 太阳黑子的一步预测结果及预测的相对误差

3.3 预测分析

实验结果显示GA-BP网络比纯BP网络在预测精度及适应能力方面有较强的优势。

首先,相对于BP网络,GA-BP网络有较高的预测精度。图5和图6显示后者比前者高得多的精度,表3中的MSE也反映出两者预测性能的差异。事实上,遗传算法应用于神经网络之所以明显降低了神经网络陷入局部最优的可能性,是因为它通过单独优化权重和阈值,在全局层面尽可能地找到误差能

量最小的基因链,减少了单纯BP神经网络易振荡不收敛(或局部收敛)的可能性(特别是在隐含层选得不太合适的情况下)。

其次,GA-BP网络比纯BP网络有更强的适应性。在相同的隐含层数目条件下,图6中的BP网络实际上是不收敛的。表4中的第2、4、5和6次实验都显示BP网络不收敛,而仅有第1、3次收敛;与此相反,GA-BP网络的各次均收敛。这说明在隐含层较少的情况下,BP网络预测的稳定性较弱,因而适应性较差。这同时说明用经验公式确定隐含层神经元数目并不是绝对有效的,它在大多情况下仅提供一种参考。

然而,GA-BP网络性能优于BP网络性能是以较长时间开销为代价的,这是很明显的。因为GA-BP网络多了权值和阈值的训练过程,这个过程种群的规模、基因链的长度、迭代次数和精度的选取等都明显地影响着整个训练过程的时间。

总之,GA-BP网络以其内在机制决定了它的各种训练和预测性能。从预测的精度和适应能力方面考虑,它是有效和稳健的。

4 结束语

综上所述,本文在分析GA算法的优势和BP网络缺点的基础上,对GA-BP神经网络的原理和实现作了分析和探讨。为了有所比较,在列出BP-GA网络基因链适应度的训练过程的同时,给出了BP-GA网络和BP网预测的对比曲线,并对两类网络的预测性能给予了定性和定量的分析。预测结果表明,基于GA-BP算法的预测性能优于纯BP网络算法。

参 考 文 献

- [1] OZKAYA B, DEMIR A, BILGILI M S. Neural network prediction model for the methane fraction in biogas from field-scale landfill bioreactors[J]. Environmental Modeling & Software, 2007, 22(6): 815-822.
- [2] FARSI H, GOBAL F. Artificial neural network simulator for supercapacitor performance prediction[J]. Computational Materials Science, 2007, 39(3): 678-683.
- [3] 钮永胜, 赵新民, 孙金玮. 采用基于神经网络的时间序列预测器的传感器故障诊断新方法[J]. 仪器仪表学报, 1998, 19(4): 383-387.
- NIU Yong-sheng, ZHAO Xin-min, SUN Jin-wei. Sensor failure detection based on time series predictor using neural network[J]. Chinese Journal of Scientific Instrument, 1998, 19(4): 383-387.
- [4] VERMAAK J, BOTHA E C. Recurrent neural networks for short-term load forecasting[J]. IEEE Transactions on Power Systems, 1998, 13(1): 126-132.

- [5] 杨建刚. 人工神经网络实用教程[M]. 杭州: 浙江大学出版社, 2002.
YANG Jian-gang. Practical artificial neural network tutorial[M]. Hangzhou: Zhejiang University Press, 2002.
- [6] 柴毅, 尹宏鹏, 李大杰, 等. 基于改进遗传算法的BP神经网络自适应优化设计[J]. 重庆大学学报(自然科学版), 2007, 30(4): 91-92.
CHAI Yi, YIN Hong-peng, LI Da-jie, et al. Self-adaptation optimize BP neural network design based on the genetic algorithms[J]. Journal of Chongqing University(Natural Science Edition), 2007, 30(4): 91-92.
- [7] 李伟超, 宋大猛, 陈斌. 遗传算法的人工神经网络[J]. 计算机工程与设计, 2006, 27(2): 316-318.
LI Wei-chao, SONG Da-meng, CHENG Bin. Artificial neural network based on genetic algorithm[J]. Computer Engineering and Design, 2006, 27(2): 316-318.
- [8] 雷英杰. MATLAB遗传算法工具箱及应用[M]. 西安: 西安电子科技大学出版社, 2005.
LEI Ying-jie. MATLAB genetic algorithm toolbox and application[M]. Xi'an: Xidian University Press, 2005.
- [9] BYUNGWHAN K, JUNGKI B. Prediction of plasma processes using neural network and genetic algorithm[J]. Solid-State Electronics, 2005, 49: 1576-1580.
- [10] YANG L, DAWSON C W, BROWN M R, et al. Neural network and GA approaches for dwelling fire occurrence prediction[J]. Knowledge-Based Systems, 2006, 19(4): 213-219.
- [11] 范睿, 李国斌, 景韶光. 基于实数编码遗传算法的混合神经网络算法[J]. 计算机仿真, 2006, 23(1): 161-162.
FAN Rui, LI Guo-bin, JING Shao-guang. A method of mixed neural network based on real-coded genetic algorithm[J]. Computer simulation, 2006, 23(1): 161-162.
- [12] 田旭光, 宋彤, 刘宇新. 结合遗传算法优化BP神经网络的结构和参数[J]. 计算机应用与软件, 2004, 21(6): 69-71.
TIAN Xu-guang, SONG Tong, LIU Yu-xin. Optimizing the structure and parameters of BP neural network based on genetic algorithm[J]. Computer Applications and Software, 2004, 21(6): 69-71.
- [13] BAREAU B, TELIALA I, KAISA S. Neural networks and genetic algorithms for bankruptcy predictions[J]. Expert Systems With Applications. 1996, 1(4): 407-413.
- [14] SRINIVAS M, PATNAIK L M. Genetic search: Analysis using fitness moments[J]. IEEE Transactions on Knowledge and Data Engineering, 1996, 8(1): 120-133.
- [15] 飞思科技产品研发中心. 神经网络理论与MATLAB7实现[M]. 北京: 电子工业出版社, 2005: 260-262.
Feisi Technology Products R & D Center. Neural network theory and realization with MATLAB7[M]. Beijing: Publishing House of Electronics Industry, 2005: 260-262.
- [16] 徐科, 徐金梧, 班晓娟. 基于小波分解的某些非平稳时间序列预测方法[J]. 电子学报, 2001, 29(4): 566-568.
XU Ke, XU Jin-wu, BAN Xiao-juan. Forecasting of some non-stationary time series based on wavelet Decomposition[J]. Acta Electronica Sinica, 2001, 29(4): 566-568.
- [17] 罗航, 王厚军, 龙兵. 基于“松散型”小波神经网络的时间序列预测研究[J]. 计算机工程与应用, 2008, 44(8): 16-17.
LUO Hang, WANG Hou-jun, LONG Bing. Research about time-serial prediction based on relaxing wavelet neural-net[J]. Computer Engineering and Applications, 2008, 44(8): 16-17.

编辑 漆蓉



黄建国, 教授, 硕士生导师。1982年毕业于电子科技大学电子工程专业。现任电子科技大学自动化工程学院“测试技术与仪器”研究所所长。先后主持设计完成多项军用电子装备的研制, 曾荣获电子工业部科技进步一等奖、国家级科技进步二等奖等。目前主要从事电子测量、系统集成、自动化控制等方面的科研工作。发表论文十余篇, 其中多篇被SCI、EI检索。