

文章编号: 1004-4353(2016)04-0351-06

# 一种改进的 IPSO-BP 神经网络在股指预测中的应用 ——以上证综指为例

黄宏运<sup>1</sup>, 吴礼斌<sup>2\*</sup>, 李诗争<sup>1</sup>, 吕石山<sup>1</sup>, 刘琪<sup>2</sup>

( 1. 安徽财经大学 金融学院; 2. 安徽财经大学 统计与应用数学学院: 安徽 蚌埠 233000 )

**摘要:** 针对股票数据具有规模庞大、结构复杂、多噪声和高度模糊非线性等特点而导致预测难的问题,利用改进的粒子群算法(固定惯性因子动态化)优化 BP 网络权阈值,建立了一个基于历史日收盘价、最低价、最高价、成交量、成交额、涨跌幅为输入变量,日开盘价为输出变量的预测模型. 利用 MATLAB 软件对 2007 年 1 月 4 日至 2015 年 8 月 31 日上证综指(开盘价)进行了仿真预测,并且从绝对误差与相对误差等角度对比分析了 BP 网络优化前后的预测结果,结果表明 IPSO 优化后的 BP 网络不仅可以更快地实现收敛寻优,而且在对未来股价的趋势判断与指数预测方面均具有较好的预测效果.

**关键词:** 股票指数; 预测; BP 神经网络; PSO 算法; 动态惯性因子

**中图分类号:** TP183; F830. 91; O29      **文献标识码:** A

## An improved IPSO-BP neural network in stock market index forecasting — A case study of Shanghai Composite Index

HUANG Hongyun<sup>1</sup>, WU Libing<sup>2\*</sup>, LI Shizheng<sup>1</sup>, LYU Shishan<sup>1</sup>, LIU Qi<sup>2</sup>

( 1. School of Finance, Anhui University of Finance and Economics; 2. Institute of Statistics and Applied Mathematics, Anhui University of Finance and Economics: Bengbu 233000, China )

**Abstract:** For the stock data has the characteristics of large scale, complex structure, multi-noise and highly fuzzy nonlinearity, resulting in the forecast for the stock index has been a difficult problem. This paper uses an Back Propagation Neural Network Optimized by an Improved Particle Swarm algorithm (Dynamic the Fixed Inertia Factor) to establishe a forecasting model based on the historical closing price, the lowest price, the highest price, the trading volume, the turnover, the rising price as the input variable and the daily opening price as the output variable. Using MATLAB software to predict the Shanghai Composite Index (opening price) from Jan. 4, 2007 to Aug. 31, 2015, and the results of BP Neural Network Optimized before and after was compared and analyzed in terms of absolute error and relative error. It is concluded that the BP Neural Network Optimized by the IPSO algorithm has a better effect on the future stock price trend judgment and index forecasting.

**Keywords:** stock index; prediction; BP neural network; particle swarm optimization; dynamic inertia factor

随着我国居民生活水平的不断提高和国内金融市场的不断发展,投资股票已逐渐成为人们投资理财的一种重要方式. 在股票投资中,股票指数的走势对投资者具有重要影响,但由于股票数据具有规模庞大、结构复杂、多噪声和高度模糊非线性等特点,因而对于股指的准确预测一直是难以

收稿日期: 2016 - 09 - 26      \* 通信作者: 吴礼斌(1962—),男,副教授,研究方向为数量经济学.

基金项目: 国家自然科学基金资助项目(11301001);安徽高等学校省级自然科学基金资助项目(KJ2013Z001);安徽财经大学校级重点研究项目(ACKY1402ZD)

解决的问题之一. 目前尽管有很多学者提出了不同的预测方法, 如: 基于基本面或技术指标的趋势预测<sup>[1]</sup>、时间序列预测<sup>[2-3]</sup>、灰色预测<sup>[4-5]</sup>和组合预测<sup>[6]</sup>等等, 但预测的准确性并不十分理想. 随着人工智能算法在经济金融领域的不断发展, BP 神经网络也在股指预测中得到了一定的应用<sup>[7]</sup>, 但是由于网络训练过程中容易受到随机因素的影响, 并且 BP 网络本身也存在学习收敛速度慢、易陷于局部极小值等问题, 因而使得该方法的应用受到一定的局限. 本文尝试利用改进的粒子群优化算法(PSO)来优化 BP 网络结构中的权阈值, 以提高股指预测的准确性.

### 1 数据来源与相关假设

本文的数据来源为国泰安 CSMAR 财经数据库提供的自 2007 年 1 月 4 日至 2015 年 8 月 31 日的上证综指, 数据的格式为 2107 行乘 7 维, 其中每一行代表每一日的开盘价、收盘价、最低价、最高价、成交量、成交额和涨跌幅. 为了数据处理方便, 本文假设以下几点: 1) 假设所获取的数据真实、准确和可靠; 2) 假设对数据进行适当的归一化处理不会对预测结果产生显著影响; 3) 假设在研究期间内未出现大的金融市场动荡或货币危机.

## 2 PSO 算法优化的 BP 网络在股指预测中的应用

### 2.1 BP 神经网络理论

BP(Back Propagation)网络<sup>[8]</sup>是一种多层前向型的神经网络, 由于在网络的训练过程中, 其调整权阈值的梯度学习算法遵循了误差反向传播机制, 所以它是目前理论最成熟、应用最广泛的人工神经网络. BP 神经网络一般是具有 3 层或者 3 层以上神经元的神经网络, 包括输入层、隐含层和输出层, 上下层之间实现全连接, 而同一层神经元之间无连接, 其拓扑结构如图 1 所示. 图 1 中  $w_{ij}$  和  $w_{jk}$  分别表示输入层神经元与隐含层神经元和隐含层神经元与输出层神经元之间的连接权值, 隐含层或输出层的任一神经元在对前一层所有神经元传来的信息进行整合时, 通常会添加一个阈值  $b$  以起到激活神经元的作用. 当一对学习样本提

供给输入层神经元后, 神经元的激活值从输入层经过各隐含层向输出层传播, 然后按照减少网络输出与实际输出样本之间误差的方向, 从输出层方向反向经过各个隐含层回到输入层, 从而逐步修正各层之间的连接权阈值, 这种算法即被称为误差反向传播算法<sup>[9]</sup>或负梯度修正算法<sup>[10]</sup>.




图 1 BP 神经网络拓扑结构

根据上述原理, 以下给出简单的 BP 神经网络算法的实现过程: 假设  $\mathbf{X}=(x_{ij})$  是一个样本输入矩阵( $i=1,2,\cdots,n;j=1,2,\cdots,p$ ), 每一行代表一组观测值, 且每一组输入观测值对应一个输出值, 整体样本的实际输出样本为  $\mathbf{Y}=[y_1\ y_2\ \cdots\ y_n]^T$  (这里为了简单说明问题只指定了一个输出值, 在实际问题中可能一组输入变量对应多个输出值, 但两者无本质上的区别), 每一列可以理解为一个指标或属性, 那么输入层的输入  $\mathbf{I}_1$  即为  $\mathbf{X}$ . 由于输入层与输出层处的激励函数通常为线性函数, 因此广义上得到输入层神经元的输出  $\mathbf{O}_1$  即为  $\mathbf{X}$ .

假设隐含层神经元的个数为  $m$  个, 对应的权值矩阵为  $\mathbf{W}=(w_{ij})\ (i=1,2,\cdots,m;j=1,2,\cdots,p)$ , 阈值矩阵为  $\mathbf{B}=(b_1,b_2,\cdots,b_m)^T$ , 那么隐含层的输入为

$$\mathbf{I}_2=\mathbf{W}_{m\times p}\times\mathbf{X}'_{p\times n}+\mathbf{B}\times\text{ones}_{1\times n}.\tag{1}$$

通常隐含层神经元的激励函数为单极 S 型函数, 即 Sigmoid 函数, 其表达式为

$$f(x)=(1+e^{-x})^{-1},\tag{2}$$

则隐含层的输出为  $\mathbf{O}_2=f(\mathbf{I}_2)$ . 输出层的输入与隐含层的输入类似:

$$\mathbf{I}_3=\mathbf{W}_{jk}\times\mathbf{O}_2+\mathbf{B}_{jk}\times\text{ones}_{1\times n}.\tag{3}$$

对于第 3 层的输出, 因传递函数为线性函数, 所以可以认为  $\mathbf{O}_3=\mathbf{I}_3$ .

以下本文利用链式偏微分法则来计算输出层与隐含层和隐含层与输入层连接权阈值的调整

量,计算结果如下:

$$\Delta W_{jk} = -\eta \frac{\partial E}{\partial W_{jk}} = -\eta(Y - O_3) \times O_2', \quad (4)$$

$$\Delta B_{jk} = -\eta \frac{\partial E}{\partial W_{jk}} = -\eta(Y - O_3) \times \text{ones}_{n \times 1}. \quad (5)$$

由公式(2)可知  $f'(x) = f(x)[1 - f(x)]$ , 进一步计算得到隐含层的权阈值调整量为:

$$\Delta W_{ij} = -\eta \frac{\partial E}{\partial W_{ij}} = -\eta W'_{jk}(Y - O_3)O_2(1 - O_2), \quad (6)$$

$$\Delta B_{ij} = -\eta \frac{\partial E}{\partial B_{ij}} = -\eta W_{ij}(Y - O_3)O_2(1 - O_2) \times \text{ones}. \quad (7)$$

BP神经网络的误差反向传播算法事实上就是将每一次权阈值的调整量与前一次的权阈值相整合,直至得到误差最小的最优状态,其具体的调整过程如下:

$$W_{ij}(t+1) = -\eta \frac{\partial E}{\partial W_{ij}} + W_{jk}(t) = \Delta W_{jk} + W_{jk}(t), \quad (8)$$

$$B_{jk}(t+1) = -\eta \frac{\partial E}{\partial B_{jk}} + B_{jk}(t) = \Delta B_{jk} + B_{jk}(t), \quad (9)$$

$$W_{ij}(t+1) = -\eta \frac{\partial E}{\partial W_{ij}} + W_{ij}(t) = \Delta W_{ij} + W_{ij}(t), \quad (10)$$

$$B_{ij}(t+1) = -\eta \frac{\partial E}{\partial B_{ij}} + B_{ij}(t) = \Delta B_{ij} + B_{ij}(t). \quad (11)$$

从上述BP算法理论的推导中可以看出,误差通过从输出层到隐含层的反向传播实现了连接权阈值的不断最优调整过程,但是在实际的算法实现过程中,权阈值通常是通过随机数来产生的,因而不易获得一组合适的权阈值。

## 2.2 PSO 算法

粒子群优化算法<sup>[11-12]</sup>(Particle Swarm Optimization, PSO)是智能算法领域除遗传优化算法<sup>[13]</sup>(Genetic Optimization)、蚁群优化算法<sup>[14]</sup>(Ant Colony Optimization)之外的又一种群体进化算法,这几种算法都是从产生随机解开始,通过不断迭代寻找最优解,并通过适应度函数评估解的质量。但是相比较遗传优化算法而言,粒子群优化算

法没有选择(Select)、重组(Recombine)和变异(Mutate)等过程,原理更加简单,操作更加方便,所以本文选择PSO算法来实现对BP网络权阈值的寻优。

PSO算法的原理为:假设在一个 $D$ 维的搜索空间中,有 $m$ 个粒子组成一个群体,其中第 $i$ 个粒子( $i=1,2,\dots,m$ )的位置表示为 $X_i=(x_i^1, x_i^2, \dots, x_i^D)$ . 每个粒子的位置即为一个搜索空间内的潜在解,将 $X_i$ 带入适应度评估函数中即可以确定解的优劣. 单个粒子经过的最好位置记为 $P_i=(p_i^1, p_i^2, \dots, p_i^D)$ , 称作个体极值(Pbest); 整个群体所有粒子经过的最好位置即为 $P_g=(p_g^1, p_g^2, \dots, p_g^D)$ , 称作全局极值(Gbest). 粒子 $i$ 的速度记为 $V_i=(v_i^1, v_i^2, \dots, v_i^D)$ , 粒子 $i$ 采用下列公式对粒子所在的速度与位置进行更新:

$$v_i^d(t+1) = \omega v_i^d(t) + c_1 r_1 (p_i^d(t) - x_i^d(t+1)) + c_2 r_2 (p_g^d(t) - x_i^d(t+1)), \quad (12)$$

$$x_i^d(t+1) = x_i^d(t) + \alpha \times v_i^d(t). \quad (13)$$

其中: $i=1,2,\dots,m$ ;  $d=1,2,\dots,D$ ;  $\omega$ 为非负数,称作惯性因子;  $c_1$ 和 $c_2$ 称作加速因子;  $r_1$ 和 $r_2$ 为 $[0,1]$ 内的随机数;  $\alpha$ 为约束因子,目的是控制速度权重。

## 2.3 改进的IPSO算法

由式(12)可知,惯性因子 $\omega$ 的大小直接控制着历史的速度对当前速度的影响程度.  $\omega$ 值越大,粒子的飞翔幅度越大,就能够较大幅度地离开原先的寻优轨道,偏离到新的方向上进行搜索,有利于跳出局部最优陷阱,进行全局寻优;  $\omega$ 值越小,粒子的飞翔幅度越小,只能够继续在原先的寻优轨道上进行精细搜索,有利于局部寻优,加快算法收敛,提高搜索精度. 因而 $\omega$ 的大小直接关系到PSO算法的性能,但是在经典的PSO算法中通常都是假定 $\omega$ 为一固定值,无法很好地在局部寻优与全局寻优间做一个很好的折中。

为了在局部搜索与全局搜索之间取得最佳平衡的惯性因子,本文在算法的开始阶段将惯性因子设置得较大,这是为了使开始时在较大的解空间内进行搜索,然后随着迭代过程不断减小惯性因子,以此保证算法的后期进行更加精细化的搜索,其具体的计算公式为:

$$\omega = \omega_{\min} + (\omega_{\max} - \omega_{\min}) \frac{Maxiter - iter}{Maxiter},$$

(14)

其中  $\omega_{\min}$  和  $\omega_{\max}$  分别为开始时和终止时的惯性因子,  $Maxiter$  为最大的迭代次数,  $iter$  为当前的迭代次数. 为了区分改进前后的 PSO 优化算法, 将改进后的 PSO 优化算法 (Improved Particle Swarm Optimization) 简记为 IPSO.

2.4 PSO 算法优化 BP 网络原理

由于 BP 网络在训练的过程中, 初始的权阈值易受到随机因素的干扰, 因此导致网络收敛速度慢、易陷入局部最优陷阱等问题, 而粒子群算法具有很好的非线性寻优能力, 所以利用 PSO 算法来优化 BP 网络权阈值可以很好地弥补网络本身存在的不足. PSO 算法优化 BP 网络的具体步骤如下:

Step1 初始化粒子群的规模、速度、位置、惯性因子、加速常数和最大迭代次数.

Step2 初始适应度值评估. 根据初始化粒子位置得到网络的初始权阈值, 用训练数据训练网络后得到预测输出, 把预测输出与实际输出之间的均方误差作为个体适应度评估值, 其计算公式为:

$$F = mse(\mathbf{Y} - \mathbf{O}) = \frac{1}{n} \sum_{i=1}^n (y_i - o_i)^2.$$

(15)

Step3 将初始适应度值作为当期每个粒子的局部最优值, 并将最佳初始适应度值(最小均方差)作为当前粒子群的全局最优值.

Step4 根据公式(12)、(13)和(14)更新每个粒子的速度和位置.

Step5 比较当期每个粒子的适应度值是否比历史局部最优值好, 如果好, 则将当期粒子适应度值作为粒子的局部最优值.

Step6 在当前局部最优值中找出全局最优值(最小适应度粒子), 并将当期全局最优值对应的位置作为粒子群的全局最优解所在的位置.

Step7 重复 Step4—6, 直至达到最大迭代次数.

Step8 输出粒子群全局最优值对应的位置, 即作为 BP 网络训练的初始权阈值.

根据上述步骤, 粒子群算法优化 BP 网络的示意图如图 2 所示.

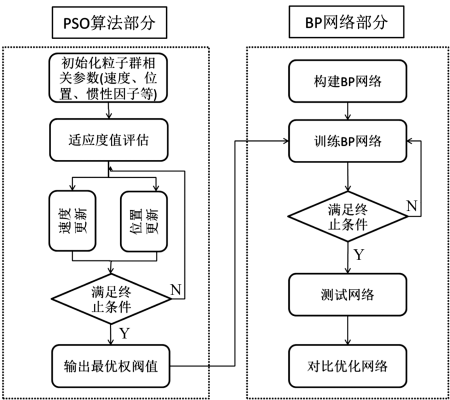


图 2 PSO 算法优化 BP 网络流程图

2.5 IPSO-BP 网络股指预测模型

2.5.1 模型的建立 考虑到投资者在对未来股价进行预判时, 通常都是参考股票的历史价量信息, 如近期的基本面状况、技术指标走势等等, 所以在模型的建立过程中, 本文将历史收盘价、最低价、最高价、成交量、成交额和涨跌幅作为输出变量, 对应的开盘价作为输入变量, 即网络的输入层含有 6 个神经元, 输出层含有 1 个神经元, 具体模型的表达式如下:

$$y(t) = f(o(t), l(t), u(t), q(t), e(t), p(t)),$$

(16)

其中  $y(t)$  为网络的输出变量(收盘价),  $o(t)$ 、 $l(t)$ 、 $u(t)$ 、 $q(t)$ 、 $e(t)$  和  $p(t)$  为网络的输入变量(收盘价、最低价、最高价、成交量、成交额、涨跌幅).

2.5.2 模型的准备 在进行模型训练之前, 除了需要对样本数据进行一定的预处理外, 还需要利用粒子群算法来寻找一组最优的初始权阈值, 具体步骤如下:

Step1 数据预处理. 为了消除各指标数据之间的数量级与量纲差异, 先进行归一化处理, 通过公式  $x' = b + (a - b) \frac{x - x_{\min}}{x_{\max} - x_{\min}}$  将原始各项指标数据归一化至区间  $[a, b]$  上, 这里  $x'$  表示归一化的各维数据,  $x$  表示原始各维数据,  $x_{\min}$  和  $x_{\max}$  表示各维数据的最小值与最大值, 本文采取  $[0, 1]$  归一化处理.

Step2 划分训练集与测试集样本. 考虑到 2015 年股票市场于 6 月至 8 月期间经历了一场牛熊市场转换, 这与 2007 年股票市场的变化规律十分相似, 所以本文将前 2000 份样本(2007 年 1 月 4



日至 2015 年 3 月 30 日)作为训练样本数据,后 107 个交易日(2015 年 3 月 31 日至 2015 年 8 月 31 日)数据作为测试样本。

Step3 粒子群算法寻优. 本文设置的粒子群的规模为 50 个,惯性因子按照公式(11)从 0.95 线性递减至 0.65,加速因子参照文献[15]的研究结果均取 2.05,算法终止的最大迭代次数为 800 次,粒子的初始位置与速度均通过随机数产生,整个迭代过程粒子的最优适应度值与平均适应度值变化如图 3 所示. 从图 3 可以看出,改进后的 IPSO-BP 比传统的 PSO-BP 更快地实现了收敛,并且对全局最优值的搜索能力也得到显著增强。




图 3 粒子群适应度值变化

完成上述 3 个步骤之后,即获得一组基于最小均方差的网络权阈值,然后在这基础之上,重新对 BP 网络进行训练. 具体网络的训练参数为:隐含层神经元个数为 50 个,传递函数为单极 S 型函数,训练函数为梯度下降的 BP 训练算法函数 `traingd`,最大训练次数为 2 000 次,学习速率为 0.1,学习最小均方差目标为 0.000 004。

2.5.3 模型的测试 利用训练好的网络对测试

集数据进行仿真,以下分别从趋势判断与指数预测精度两个方面对比 IPSO-BP 与 PSO-BP 的预测结果。

1) 趋势预测. 绘制测试集 107 天的股指预测结果,如图 4 所示. 从图 4 可以直观地看出,IPSO-BP 对股指的趋势预测与原始股指走势基本保持一致,并且在股价波动幅度较大的时段(如图 4 中所示的第 40—60 个交易日)也实现了较好的仿真,预测结果明显好于 PSO-BP。




图 4 IPSO-BP 与 PSO-BP 的预测结果

2) 指数预测. 选取测试集 14 个交易日的股指预测结果,并对预测的绝对误差与相对误差进行统计,结果见表 1. 从表 1 的统计结果来看,IPSO-BP 网络的预测误差基本上都位于 10 个指数点以内,相对误差在 0.25 个百分点以内;而 PSO-BP 网络的预测误差在多个交易日均超过了 10 个指数点,相对误差也明显超过了 0.25 个百分点. 为了更直观地比较两者的预测精度,绘制了预测绝对误差与相对误差的对比图,如图 5 所示. 从图 5 可以看出,IPSO-BP 网络预测的绝对误差与相对误差集中分布于 0 界线附近,说明其预测的精度明显高于 PSO-BP 网络预测。

表 1 2015 年 3 月 31 日至 2015 年 4 月 20 日股指预测的绝对误差与相对误差

样本日期	实际 开盘价	IPSO-BP 神经网络			PSO-BP 神经网络		
		预测值	绝对误差	相对误差/%	预测值	绝对误差	相对误差/%
2015/3/31	3 822.99	3 831.94	8.95	0.23	3 838.5	6.56	0.17
2015/4/1	3 748.34	3 741.81	6.53	-0.17	3 728.97	12.84	-0.34
2015/4/2	3 827.69	3 833.31	5.62	0.15	3 822.75	10.56	-0.28
2015/4/3	3 803.38	3 807.63	4.25	0.11	3 815.52	7.89	0.21
2015/4/7	3 899.42	3 904.12	4.7	0.12	3 892.89	11.23	-0.29
2015/4/8	3 976.53	3 973.95	2.58	-0.06	3 961.59	12.36	-0.31
2015/4/9	4 006.13	4 000.57	5.56	-0.14	3 980.21	20.36	-0.51
2015/4/10	3 947.49	3 940.04	7.45	-0.19	3 948.99	8.95	0.23
2015/4/13	4 072.72	4 081.35	8.63	0.21	4 088.83	7.48	0.18
2015/4/14	4 125.78	4 138.41	12.63	0.31	4 131.3	7.11	-0.17
2015/4/15	4 135.65	4 145.51	9.86	0.24	4 148.77	3.26	0.08
2015/4/16	4 055.92	4 053.57	2.35	-0.06	4 044.62	8.95	-0.22
2015/4/17	4 254.72	4 257.1	2.38	0.06	4 266.94	9.84	0.23
2015/4/20	4 301.35	4 309.18	7.83	0.18	4 324.44	15.26	0.35




图 5 IPSO-BP 与 PSO-BP 股指预测的绝对误差与相对误差的对比

3 结束语

本文利用改进后的 IPSO 算法(惯性因子动态化)对 BP 网络进行优化,结果表明该方法较传统的 PSO-BP 算法在收敛速度、全局最优值的搜索能力等方面均有明显提高,因此该方法在实际的股指预测中,可更为准确地对未来的股价、指数等作出预测;但是,因受到短期波动因素的影响,IPSO-BP 网络在股指的精准预测方面仍存在着一定的不足,尤其是在股价波动幅度大时,预测的指数会出现一定的失真现象。

粒子群算法作为三大经典的群体智能<sup>[16]</sup>(Swarm Intelligence, SI)算法之一,除本文采用的线性递减惯性因子法之外,还有模糊惯性因子<sup>[17]</sup>(FIW)、随机惯性因子<sup>[18]</sup>(RIW)和动态化加速因子等改进方法,并且也都实现了对传统粒子群算法的改进.随着各种智能算法的融合与发展,有望实现在股指方面更加理想的协同预测,比如利用基于 Boltzman 机<sup>[19]</sup>的模拟退火算法<sup>[20]</sup>(Simulated Annealing, SA)来进一步优化 PSO 算法。

参考文献:

[1] 丁忠明,黄华继.证券投资学[M].北京:高等教育出版社,2013:180-270.

[2] 潘贻超.多元时序与滞后协整混合模型及其在股指预测中的应用[D].湖北:武汉理工大学,2007.

[3] 张晶,王宏勇.股指时间序列的分形分析及预测[J].南京财经大学学报,2013,23(5):75-80.

[4] 姚婷,张晶,沈磊.基于灰色系统理论的股指预测研究[J].河南工程学院学报,2013,25(4):71-75.

[5] 李嵩松,惠晓峰.股票指数模糊随机预测与灰色预测实证比较研究[J].哈尔滨工业大学学报(社会科学版),2010,12(5):1-6.

[6] 汪同三,张涛.组合预测理论、方法及应用[M].北京:社会科学文献出版社,2008:56-70.

[7] 刘晓敏.基于 BP 神经网络的股指预测研究[D].大连:大连理工大学,2012.

[8] Gao Xuejun, Huang Tingwen, Wang Zhenyou, et al. Exploiting a modified gray model in back propagation neural networks for enhanced forecasting[J]. Cognitive Computation, 2014,6(3):331-337.

[9] 刘彩红. BP 神经网络学习算法的研究[D].重庆:重庆师范大学,2008.

[10] 王俊清. BP 神经网络及其改进[J].重庆工学院学报(自然科学版),2007,21(3):75-77.

[11] Ting Tiew-On, Rao M V C, Loo C K, et al. Solving unit commitment problem using hybrid particle swarm optimization[J]. Journal of Heuristics, 2003,35(6):76-81.

[12] Qu Guodong, Lou Zhonghua. Application of particle swarm algorithm in the optimal allocation of regional water resources based on immune evolutionary algorithm[J]. Journal of Shanghai Jiaotong University (Science), 2013,18(5):634-640.

[13] Tan Guanzheng, Bao Kun, Richard Maina Rimiru. A composite particle swarm algorithm for global optimization of multimodal functions[J]. Journal of Central South University, 2014,21(5):71-79.

[14] 葛继科,邱玉辉,吴春明,等.遗传算法研究综述[J].计算机应用研究,2008,25(10):2912-2915.

[15] Clerc M, Kennedy J. The particle swarm— explosion, stability, and convergence in a multidimensional complex space[J]. IEEE Transactions on Evolutionary Computation, 2002,6(1):58-73.

[16] 刘峡壁.人工智能导论[M].北京:国防工业出版社,2008:257-260.

[17] Shi Y, Eberhart R C. Fuzzy adaptive particle swarm optimization[J]. IEEE Congress on Evolutionary Computation, 2001,1:101-106.

[18] Eberhart R C, Shi Y. Tracking and optimizing dynamic systems with particle swarms[J]. IEEE Congress on Evolutionary Computation, 2001, 1:94-100.

[19] JIANG Tao, GONG Qiwei, QIU Ruofan, et al. Immiscible multicomponent lattice Boltzmann model for fluids with high relaxation time ratio [J]. Pramana, 2014,83(4):557-570.

[20] 杨汉桥,林晓辉.遗传算法与模拟退火法寻优能力综述[J].机械制造与自动化,2010,26(2):73-75.