

量子粒子群优化神经网络集成股市预测模型研究

A Neural Network Ensemble Forecasting Model Research of Stock Market Based on Quantum Particle Swarm Optimization

汪灵枝^{1,2}, 罗朝晖³, 韦增欣², 赵秋梅²

WANG Ling-zhi^{1,2}, LUO Chao-hui³, WEI Zeng-xin², ZHAO Qiu-mei²

(1. 柳州师范高等专科学校数学与计算机科学系, 广西柳州 545004; 2. 广西大学数学与信息科学学院, 广西南宁 530004; 3. 百色学院数学与计算机科学系, 广西百色 533000)

(1. Department of Mathematics and Computer Science, Liuzhou Teachers College, Liuzhou, 545004, China; 2. College of Mathematics and Information Science, Guangxi University, Nanning, Guangxi, 530004, China; 3. Department of Mathematics and Computer Science, Baise University, Baise, Guangxi, 533000, China)

摘要:利用量子粒子群优化神经网络集成个体的网络结构和连接权值,对集成个体进行支持向量机回归集成,建立一个新的量子粒子群优化神经网络集成股市预测模型。新模型能有效提高神经网络集成系统的泛化能力,易操作,稳定性好,预测精度高,具有良好的应用前景。

关键词:优化 股市预测 量子粒子群 支持向量机 神经网络 集成

中图分类号:O224, TP18 **文献标识码:**A **文章编号:**1005-9164(2010)04-0324-04

Abstract: A novel neural network ensemble forecasting model based on quantum particle swarm optimization (QPSO) was proposed. The QPSO algorithm is used to evolve neural network architecture and connection weights, to generate different individual of neural network. Then Support Vector Machine is used for regression ensemble. Empirical results reveal that the prediction is generalization ability. The illustration and testing reveal that the ensemble model proposed can be used as an alternative forecasting tool for stock market forecasting in achieving greater accuracy and improving prediction quality further.

Key words: optimization, stock market forecast, quantum behaved particle swarm optimization, support vector machine, neural network, ensembles

二十几年来,利用人工神经网络进行股市预测一直是证券分析者关注的热点,取得了一定的预测效果^[1~3]。但是由于缺乏严密的理论体系指导、爬坡能力差、易过度拟合等不足使得网络学习系统的泛化能力不强,预测精度不稳定。1990年,L. K. Hanson和P. Salamon^[4]开创性提出了神经网络集成方法,并证明可以简单地通过训练多个神经网络并将其结果通过相对多数或绝对多数投票法进行合成,就能显著提高网络泛化能力,即显著提高网络预测精确度。这为

股市预测提供了一个崭新的研究思路。Sun等^[5]将量子行为引入粒子群算法,利用量子测不准原理代替牛顿力学来确定粒子的行为,提出量子粒子群优化(QPSO)算法。在QPSO算法中,粒子能以一定概率自由出现在搜索空间的任意位置,有效克服“早熟收敛”现象,QPSO算法全局寻优能力要远远强于标准的粒子群优化(PSO)算法。为此,本文利用量子粒子群优化神经网络集成个体的结构和初始连接权值,提高个体网络的泛化能力,形成一组优良的神经网络集成个体,进而利用支持向量机回归集成,生成神经网络的输出结论,建立一个新的股市预测模型。

收稿日期:2010-03-11

作者简介:汪灵枝(1974-),男,副教授,主要从事最优化算法、人工智能研究。

1 量子粒子群优化神经网络集成算法

1.1 量子粒子群优化集成个体网络

根据训练方法的不同,可以把人工神经网络分为两种:自组织神经网络和逆向传播神经网络。逆向传播神经网络又称为BP神经网络,是一种基于误差反向传播算法的多层前馈神经网络^[6],目前在神经网络学习中应用最为广泛。我们以BP神经网络作为集成个体网络开展训练,由此建立QPSO优化BP神经网络算法(QPSO-BP算法)。

QPSO-BP算法的粒子定义为:BP算法中的初始化权值和阈值。每个粒子的适应度定义为: $f(\cdot) = (1 - \bar{E})^{-1}$,其中 $\bar{E} = \frac{1}{n_1} \sum_{k=1}^{n_1} \sum_{t=1}^m (y_k(t) - \hat{y}_k(t))^2$, $y_k(t)$ 为第K个样本的期望输出, $\hat{y}_k(t)$ 为第K个样本的实际输出。

QPSO算法的算法方程^[5]为:

$$p_d = \frac{\varphi_1 \times p_{d1} + \varphi_2 \times p_{d2}}{\varphi_1 + \varphi_2}, \quad (1)$$

$$m_{best} = \frac{1}{n_1} \sum_{i=1}^{n_1} p_i = \left[\frac{1}{n_1} \sum_{i=1}^{n_1} p_{i1}, \dots, \frac{1}{n_1} \sum_{i=1}^{n_1} p_{id} \right], \quad (2)$$

$$x(t+1) = p + \beta \times |m_{best} - x(t)| \times \ln\left(\frac{1}{u}\right), \quad (3)$$

其中: $p_d = (p_1, \dots, p_d)$, p_d 是该粒子在第d维的值; φ_1, φ_2 是(0,1)间的随机数; n_1 是粒子总个数; p_i 是粒子i的全局极值; m_{best} 是中植最优位置; β 是收缩扩张系数,利用它控制算法的收敛速度。

QPSO-BP算法的流程如下:

(I)初始化一群粒子(群体规模为 n_1),包括随机位置和速度,粒子为BP算法中的初始化权值和阈值;

(II)输入一训练集,计算每个粒子的适应度;

(III)对于每个粒子,将其适应值和所经历的最好位置 p_{best} 的适应值作比较,如果较好,则将其作为当前的个体最优位置;

(IV)对于每个粒子,将其适应值和全局所经历的最好位置 g_{best} 的适应值作比较,如果较好,则将其作为当前的全局最优位置;

(V)根据方程(I)~(III)变化粒子的速度和位置;

(VI)如得到足够好的适应值或达到一个预设最大迭代数,终止程序;否则,返回(II)。

1.2 支持向量机回归集成

由于股市预测是非线性问题,所以我们选用非线性

的支持向量机回归(NRSVM)集成神经网络的集成个体。在处理非线性问题时,NRSVM通过引入核函数将输入向量映射到一个高维特征子空间,然后在高维空间中构造一个最优决策超平面,以此将非线性问题转化成高维子空间的线性问题,再利用一个合理核函数来代替高维空间中的内积计算,从而求出函数解,有效提高泛化能力和克服维数灾难问题。

NRSVM算法流程如下:

(I)给定训练样本集 $\{(x_i, y_i), i=1, 2, \dots, n\}$,期望输出 $y_i \in R, x_i \in R^n$,确定回归函数 $f(x) = \omega \cdot \phi(x) + b$,误差损失函数

$$L(y - f(x), x) = |y - f(x, \omega)|_\epsilon = \max(|y - f(x, \omega)| - \epsilon, 0), \epsilon > 0.$$

(II)引入上下松弛变量 ξ_i 和 ξ_i^* ,惩罚系数 $C > 0$,转化求解关于变量 $\omega, b, \xi_i, \xi_i^*$ 的最优化问题:

$$\min \phi(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*),$$

$$\text{s. t. } \begin{cases} y_i - \omega \cdot \phi(x) - b \leq \epsilon + \xi_i \\ \omega \cdot \phi(x) + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* > 0, i=1, 2, \dots, n. \end{cases}$$

(III)引入拉格朗日数乘因子 $\alpha_i, \alpha_i^*, \eta_i, \eta_i^*$,适当选取核函数 $K(x_i, x_j)$,令 $K(x_i, x_j) = \langle \phi_i, \phi_j \rangle$,可以得到如下对偶表达:

$$\max W(\alpha) = \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(x_i, x_j) - \epsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*),$$

$$\text{s. t. } \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0, \\ \alpha_i, \alpha_i^* \in [0, C], i, j=1, \dots, n. \end{cases}$$

(IV)得到回归函数的表达式为

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b. \quad (4)$$

1.3 量子粒子群优化神经网络集成算法步骤

量子粒子群优化神经网络集成算法的具体步骤如下:

(I)利用QPSO-BP算法训练一组神经网络个体,生成一组神经网络集成个体;

(II)利用NRSVM算法对集成个体进行支持向量机回归集成,生成神经网络的输出结论。

2 量子粒子群优化神经网络集成股市预测模型的建立和预测效果分析

根据量子粒子群优化神经网络集成算法,我们选取2008年3月12日到2009年9月30日共385个交易日上证综合指数收盘价数据,拟合建立QPSO优化神经网络集成股市预测模型。并用后续30个交易日(2009年10月9日到11月19日)的上证综合

指数收盘价数据进行预测,检验模型的预测效果。

2.1 数据预处理

利用神经网络集成进行股市预测,输入个体因子的选取是一个很重要的问题。输入变量过多将导致网络结构复杂化,网络的学习负担加重,学习速度将下降,泛化能力将降低。鉴于此,我们采用奇异谱分析(SSA)方法^[7]对原始上证指数时间序列重构,并用均生函数(MGF)方法^[8]对重构序列构造均生函数延拓矩阵,以其作为自变量,原始上证指数时间序列作为因变量,再利用偏最小二乘(PLS)方法^[9]进行处理,提取对因变量解释最强的综合变量作为神经网络的输入因子,原始时间序列作为输出因子。

对原始的 385 个数值进行数据预处理,选取累积贡献率达到 80% 的值为数据重构,重构结果如图 1 所示。

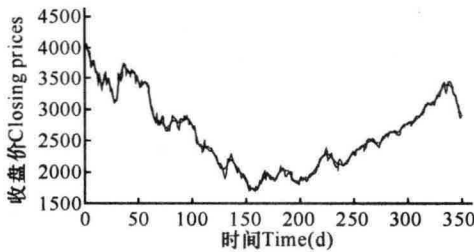


图 1 收盘价原始数据和重构数据

Fig. 1 Original data and reconstruction data for closing prices

—: 原始数据; ·····: 重构数据。

—: Actual data; ·····: Reconstruction data.

从图 1 可以看出,通过数据重构,有效提取了原序列中的主要趋势成分和震荡周期,降低了干扰,初步达到降维、降噪的目的。

2.2 模型建立与评价指标

量子粒子群优化神经网络集成股市预测模型建立方法如下:用 QPSO 优化 BP 神经网络,产生 60 个神经网络个体,利用非线性的支持向量机回归集成,建立 QPSO 优化神经网络集成股市预测模型(SVM-ANNE)。

在相同的试验条件下,我们另外建立 2 个模型来比较预测效果。

模型 1:采用 6 个技术指标作为神经网络的输入变量,借助 MATLAB 中的神经网络工具箱,通过 Bagging 技术和不同训练算法产生 60 个神经网络个体,对其简单加权平均,建立传统 Bagging 技术集成股市预测模型(ANNE)^[10];

模型 2:用标准粒子群算法优化 BP 神经网络,产生 60 个神经网络个体,对其简单加权平均,建立粒子群优化神经网络集成股市预测模型(PSO-

ANNE)^[11]。

以上 3 个模型均是经过奇异谱分析和均生函数法对原始数据序列预处理得到建模因子,再经过偏最小二乘回归进行分解和筛选,提取对原序列解释性最强的综合变量建立的非线性模型。

为了定量比较 3 个模型的优劣,我们引入以下 4 种指标:

平均相对百分比误差:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100; \quad (5)$$

均方根误差:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (6)$$

趋势准确率:

$$F = \frac{1}{n} \sum_{i=1}^n I_i \cdot 100\%; \quad (7)$$

$$\text{其中 } I_i = \begin{cases} 1, & \frac{y_{i+1} - y_i}{y_{i+1} - y_i} > 0, \\ 0, & \frac{y_{i+1} - y_i}{y_{i+1} - y_i} < 0, \end{cases} \quad i = 1, 2, \dots, n;$$

Pearson 相关系数: PR =

$$\frac{\sum_{i=1}^n (y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}}_i)}{\sqrt{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2}}; \quad (8)$$

其中, y_i 、 \hat{y}_i 分别代表实际值和神经网络的输出值。

2.3 模型预测结果与分析

从表 1 以及图 2、图 3 的结果可以看出,无论是拟合效果还是预测效果,PSO-ANNE 模型和 SVM-ANNE 模型均要优于传统的 ANNE 模型。相对而言,SVM-ANNE 模型表现出更好的拟合和预测效果。

表 1 3 个模型对收盘价拟合和预测统计结果

Table 1 Statistical results of three different models about fitting and forecasting for closing prices

模型 Model		MAPE	RMSE	F (%)	PR
ANNE	拟合 Fitting	10.60	87.6635	61.13	0.8792
	预测 Forecast	12.98	90.6018	40.00	0.7931
PSO-ANNE	拟合 Fitting	9.07	68.8543	66.57	0.9521
	预测 Forecast	11.34	36.2170	70.00	0.9041
SVM-ANNE	拟合 Fitting	2.76	49.7278	87.89	0.9865
	预测 Forecast	3.16	25.8860	83.33	0.9605

从表 1 的结果可以看出,SVM-ANNE 模型对训练样本和检测样本的各种统计指标均小于 ANNE 模

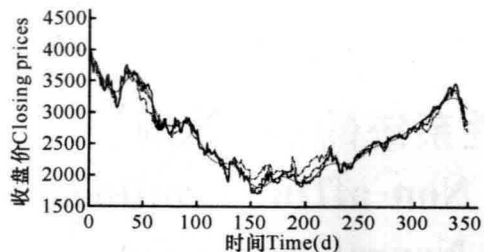


图2 3个模型对385个训练样本的收盘价拟合效果

Fig. 2 Fitting results of three different models about 385 training samples for closing prices

——:原始数据; - · - · - : ANNE 模型; ·····: PSO-ANNE 模型; ---: SVM-ANNE 模型。

——: Actual data; - · - · - : ANNE fitting; ·····: PSO-ANNE fitting; ---: SVM-ANNE fitting.

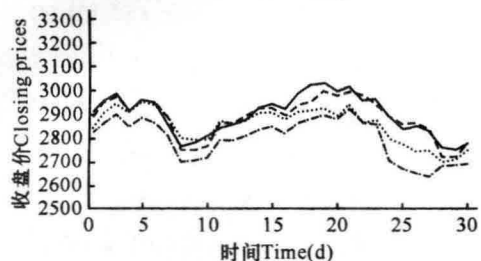


图3 3个模型对30个检测样本的收盘价预测效果

Fig. 3 Forecasting results of three different models about 30 testing samples for closing prices

——:原始数据; - · - · - : ANNE 模型; ·····: PSO-ANNE 模型; ---: SVM-ANNE 模型。

——: Actual data; - · - · - : ANNE fitting; ·····: PSO-ANNE fitting; ---: SVM-ANNE fitting.

型,显示出 SVM-ANNE 模型具有很好的学习能力和预测能力,而且预测精度也要高于其它两种模型。从图2和图3可以看出,ANNE模型在拟合和预测时能够把股市收盘价的基本趋势反映出来,说明它具有历史样本学习能力,基本上学习出了股市收盘价基本趋势,对未来具有跟踪能力,只是其拟合和预测精度不够高。由于每一个个体都是神经网络通过训练样本学习所得,整体上也就能够反映股市的输入与输出非线性映射关系,但是 ANNE 模型是 60 个神经网络个体简单平均,而没有对其个体进一步筛选和有效优化组合,如果有部分个体神经网络对系统的学习能力和预测能力没有任何作用,将其平均后系统的误差精度则无法保证。PSO-ANNE 模型的跟踪能力比 ANNE 模型有了很大进步,学习能力进一步加强,但是对有效信息筛选能力明显没有 SVM-ANNE 模型强。而 SVM-ANNE 模型是对 60 个神经网络个体进行有效的信息筛选和综合,用支持向量机对其集成,从图2和图3可以看出,它具有很好地学习股市收盘价规律的能力,对检测样本也具有很强的跟踪能力,

显示出很好的预测能力,其拟合和预测精度高于其它两个模型。同时,我们对股市开盘价利用上述方法建模,结果表明,QPSO 优化神经网络集成股市预测模型无论是在拟合还是在预测中均优于其它两个集成模型。

3 结束语

股票价格的变动充满着复杂性和不确定性,在其整个变化过程中某些阶段的变化是随机的或是人类现有装备和知识所无法预测的。但是只要充分发挥了各个神经网络集成个体的作用,分散单个神经网络的误差和不确定性,就能使得系统的泛化能力得以一定程度地提高,预测精度得以增强。实例证明,本文提出的新算法在建模样本、预报因子相同的条件下,它的拟合程度和预报精度明显得到增强,并且易操作,稳定性好,这将给利用神经网络集成进行股市预测提供一些新的思路和方法。

参考文献:

- [1] Lapedes. An information criterion for optimal neural networks election[J]. IEEE Trans Neural Networks, 1987, 2(6):490-497.
- [2] Haris, Abdullahetc. Neural networks ensemble for financial trend prediction[J]. TENCON 2000, Proceedings, 2000,3:157-161.
- [3] 吴成东. 人工神经元 BP 网络在股票预测方面的应用[J]. 控制工程, 2002, 9(5):48-51.
- [4] Hansen L K, Salamonp. Neural networks ensembles [J]. IEEE Trans Pattern Analysis and Machine intelligence, 1990, 12(10):993-1001.
- [5] Sun J, Xu W B. A Global search strategy of Quantum-Be-haved particle swarm optimization; proceedings of IEEE Conference on Cybernetics and Intelligent Systems [C]. Singapore; [s. n.], 2004; 111-116.
- [6] Simon Haykin. 神经网络原理[M]. 叶世伟, 史忠植, 译. 北京:机械工业出版社, 2004:112-121.
- [7] 袁亚湘, 孙文瑜. 最优化理论与方法[M]. 北京:北京科学出版社, 1997:35-38.
- [8] 魏凤英, 曹鸿兴. 长期预测的数学模型及其应用[M]. 北京:北京气象出版社, 1990:10-25.
- [9] 王惠文. 偏最小二乘回归方法及其应用[M]. 北京:国防工业出版社, 1999:21-25.
- [10] 周志华, 陈世福. 神经网络集成[J]. 计算机学报, 2002, 25(1):1-7.
- [11] 高海兵, 高亮, 周驰, 等. 基于粒子群优化的神经网络训练算法研究[J]. 电子学报, 2004, 32(9): 1572-1574.

(责任编辑:韦廷宗)