

6-14-2018

Combination Forecasting of Stock Index Time Series based on Cooperative Game Theory

Luo Wei

Hunan Railway Professional Technology College, Zhuzhou 412001, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Original Article is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Combination Forecasting of Stock Index Time Series based on Cooperative Game Theory

Abstract

Abstract: In view of the characteristics of nonlinear, large amplitude, frequent fluctuations in China's stock market, *a prediction method of intelligent composite stock index time series based on the cooperative game is presented. The prediction model of stock index time series is established by using neural network method based on the correlations among the various economic indicators, and the development trend and laws of stock index time series are established by using the improved ARIMA method.* The two methods are combined by importing cooperative game method. Simulation results show that the prediction accuracy of the presented method is controlled within 6.6% effectively, which has greater advantage than the single model in the index evaluation such as RMSE, MAPE and F.

Keywords

Financial time series, combination prediction, ARIMA, NN, cooperative game

Recommended Citation

Luo Wei. Combination Forecasting of Stock Index Time Series based on Cooperative Game Theory[J]. Journal of System Simulation, 2018, 30(6): 2086-2094.

基于合作对策的股指时间序列组合预测

罗伟

(湖南铁道职业技术学院, 湖南 株洲 412001)

摘要: 针对我国股市呈现出非线性、大幅度、频繁波动的特征, 提出一种股指时间序列智能组合预测方法。从多种经济指标之间的相关性出发利用神经网络方法, 建立股指时间序列预测模型; 同时从时间关联性的角度出发, 利用改进ARIMA方法, 建立辨识股指时间序列发展趋势和规律, 通过引入合作对策方法, 对两种预测方法进行组合。仿真结果表明, 采用此算法能够有效的将预测精度控制在6.6%以内, 与单一模型在RMSE、MAPE和F三项指标比较具有较大优势。

关键词: 股指时间序列; 组合预测; ARIMA; 神经网络; 合作对策

中图分类号: TP273+.21 文献标识码: A 文章编号: 1004-731X(2018)06-2086-09

DOI: 10.16182/j.issn1004731x.joss.201806011

Combination Forecasting of Stock Index Time Series based on Cooperative Game Theory

Luo Wei

(Hunan Railway Professional Technology College, Zhuzhou 412001, China)

Abstract: In view of the characteristics of nonlinear, large amplitude, frequent fluctuations in China's stock market, a prediction method of intelligent composite stock index time series based on the cooperative game is presented. The prediction model of stock index time series is established by using neural network method based on the correlations among the various economic indicators, and the development trend and laws of stock index time series are established by using the improved ARIMA method. The two methods are combined by importing cooperative game method. Simulation results show that the prediction accuracy of the presented method is controlled within 6.6% effectively, which has greater advantage than the single model in the index evaluation such as RMSE, MAPE and F.

Keywords: Financial time series; combination prediction; ARIMA; NN; cooperative game

引言

金融市场是国家经济运行的核心, 随着我国经济体制改革和金融体制改革的深入, 金融市场在长期资本融通, 资源优化配置, 金融资产价格发现, 社会财富再分配等方面的作用日益显著, 目前社会各界关心的热点问题是如何解决以下几项问题^[1-2]:

指导金融市场资源配置, 探求金融市场的变化规律, 加强金融管理工作。作为预判股市活动发展方向的基础, 股指数据能够反映股市行情走势, 是股市最重要的数据之一。因此, 在我国经济活动的开展中, 有效地分析和预测股指时间序列十分重要。

以经济规律为主导、自然因素、政策法规和文化环境等共同影响的复杂现实系统是股票市场的本质。由于这些因素的相互影响, 会减弱金融市场的本质规律、确定性及其他周期性; 同时会产生一些虚假周期, 使股指时间序列呈现出干扰因素多、周期性弱、信噪比低的特点^[3], 给分析预测股指时



收稿日期: 2016-08-06 修回日期: 2016-11-01;
基金项目: 湖南省教育厅科学研究项目(13C591);
作者简介: 罗伟(1979-), 男, 湖南株洲, 硕士, 副教授, 研究方向为控制工程。

<http://www.china-simulation.com>

• 2086 •

间序列带来挑战。

在国内外金融学领域,开展了对股指时间序列者广泛的研究,主要可分为三方面:时间序列分析、证券投资分析人工智能分析。其中证券投资分析法,主要根据对客观政治经济政策的把握以及宏观经济指标,结合交易数量和投资者心理等市场因素进行分析^[4],分析过程往往具有较大的主观随意性。

时间序列分析法,主要利用金融市场发展的规律性与连续性,统计分析股票的历史数据,来推测股指序列的未来发展趋势。如目前应用广泛的自回归条件异方差(ARCH)^[5],自回归求和移动平均(ARIMA)模型^[6]以及广义自回归条件异方差(GARCH)模型等^[7];上述方法中,仅考虑了股指时间序列自身的发展,而没有考虑到外界因素影响,预测误差较大。

在最近几年,智能算法在股指时间序列的预测中被大规模应用,其能够同时考虑多种经济指标之间的关系,对股指时间序列的发展趋势进行预测。但多种经济指标在不同时期对股指时间序列发展的参考性是动态变化的,因此此类方法也有一定的局限性。

大部分学者目前只对基于某一方法的股指时间序列的辨识进行了研究,存在固定方法无法有效修正自身缺陷、建模的数据依据单一等问题。我国股市环境复杂,应用范围受到了一定限制。

针对上述问题,本文提出一种新的股指时间序

列组合预测模型。利用 ARIMA 从时间关联性的角度建立辨识股指时间序列发展趋势和规律;同时利用神经网络方法从多种经济指标之间的相关性出发,建立股指时间序列预测模型,为了综合两种算法的优势,取长补短,本文引入合作对策方法,对两种预测方法进行组合,以达到提升精度的目的。

1 股指时间序列预测算法的提出

我国股市受到多种宏、微观因素的共同影响,与欧美等成熟市场相比,不成熟的投资者心理与市场机制,导致我国的股市表现出异常波动的特点。在对我国股市的指数波动性进行预测时,仅考虑一种算法或者一种因素难以达到较好的效果。

合作对策该数学模型有如下优点:其一,针对多个独立利益主体协调行动产生效益分配的问题,可以有效解决。其二,对多种预测方法可以综合考虑,并按照其对最终结果的贡献,进行“效益分配”,实现各种算法之间的“优势互补”。

基于以上思路,从股指时间序列自身发展为出发点,综合考虑多种经济指标,分别采用 ARIMA 模型和神经网络模型,作为单一预测方法,利用合作对策算法,融合神经网络模型和 ARIMA 模型。图 1 为其原理图,主要分为以下三部分:基于 BP 神经网络的股指时间序列建模,基于 ARIMA 的股指时间序列辨识,以及基于合作对策的组合预测。




图 1 预测算法原理图

Fig. 1 Prediction algorithm schematic diagram

首先,采用 ARIMA 辨识股指时间序列的发展趋势,并利用粒子群算法(PSO),实现 ARIMA 系数的优化选取;其次,采用 BP 神经网络对股指时间序列建模,为避免隐层传递函数对预测结果的影响,本文引入了三种隐层传递函数作为建立神经网络预测模型;最后,为了达到组合预测的目的,利用合作策略的相关理论,分配各个单一预测方法的权重系数。

2 基于 ARIMA 的股指时间序列辨识

股指时间序列在金融活动中会受到多种突发因素的影响时,会表现出较强的波动性和非平稳性。作为一种有效的金融数据分析工具,ARIMA 能够针对股指时间序列波动性和非平稳性,实现数据平稳化^[8]。因此对股指时间序列进行预测时,本文采用了 ARIMA 算法。

本文的研究对象为上证综合指数的十日移动平均线(MA)MA(10)时间序列。用如下数学公式表示基于 MA(10)时间序列的 ARIMA(p,d,q)过程:

$$\begin{cases} \Phi_p(B)\nabla^d x_t = \Theta_q(B)\varepsilon_t \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t \\ E(x_s \varepsilon_t) = 0, \forall s < t \end{cases} \quad (1)$$

式中: ε_t 为白噪声序列; d 为差分阶数; B 为延迟算子; x_t 为原序列; p 为自回归模型(AR)的阶数; q 为移动平均模型(MA)的阶数; Θ 为 q 阶 MA 模型的系数多项式; Φ_p 为 p 阶 AR 模型的自回归系数多项式。因此可知,ARIMA 就是表示 ARMA(p,q) 模型和 d 阶差分运算的组合。其实现过程为:

步骤 1 原始股指时间序列采用零均值化处理和差分平稳化处理;

步骤 2 为了确定辨识结果的结构和阶次,分析股指时间序列的截尾性时,可以通过偏自相关分析以及自相关分析的方法。

步骤 3 通过 PSO 以辨识结果阶次和结构为依据确定模型的参数;

步骤 4 检查误差,如果检验模型与原时间序

列之间的误差超出要求,则回到**步骤 2**重新辨识模型结构;

步骤 5 通过所建立的合适的模型推导出金融预测模型,并应用于股指时间序列预测。

2.1 差分定阶

由于金融市场的突发性和非平稳性,股指时间序列样本的自相关和偏相关函数往往难以快速趋于 0,必须采用差分处理,并考察后续的序列,如果含有趋势项,则继续进行差分处理。

以上证综合指数 MA(10)时间序列样本为例,经过差分两次运算后,趋势项基本可以忽略不计,本文 ARIMA(p,d,q)的差分次数 d 值取 2。

2.2 模型结构确定

ARIMA 需要进一步分析股指时间序列是否具有 AR(p)和 MA(q)的特征,才能确定具体的辨识结构^[9]。一般通过自相关函数的截尾性分析来确定。

依据截尾特性分析可知,以上证综合指数 MA(10)时间序列样本为例,实际计算发现,自相关函数 $\hat{\rho}_k$ 具有截尾性,而 a_{kk} 偏相关函数具有拖尾性,因此需要利用 ARIMA(p,d,q)的辨识结构来结合差分定阶分析。

2.3 模型定阶

以 2003 年 9 月开始的 1 000 组上证综合指数 MA(10)时间序列样本为例,计算得到的 AMAR 模型的阶数 $p=4$, $q=3$ 。

2.4 采用 PSO 参数估计

ARIMA 预测精度的关键是由 ARIMA(p,d,q) 阶数确定后的 $p+q$ 个多项式系数的取值决定的。PSO 是一种基于种群并行进化的优化算法^[10],在陷入局部最优问题上有所改善,非常适合应用于 ARIMA 参数估计中。

为了较好的解决参数估计问题,实数编码的方式由粒子位置组合成 $p+q$ 个系数,其中大量的粒子更新粒子自身速度矢量 V 时,参照物为当前位置

最优的粒子, 于解空间中迭代更新^[11], 为了找到全局最优粒子(多项式系数), 需在最优的位置逐步聚合。从而。

2.4.1 目标函数

在预测股指时间序列的问题中, ARIMA 预测模型输出的股指时间序列值应与实际的值之间会产生偏差, PSO 算法的目标函数应考虑使其偏差最小。

2.4.2 惯性因子选择

惯性因子 Ω' 决定了 PSO 的优化效果^[12], 由于 ARIMA 的多项式系数构成的 $p+q$ 维解空间搜索范围较大, 为了兼顾 PSO 的搜索范围和收敛性, 本文采用公式(6)对 Ω' 的进行调节。

$$\Omega' = \Omega_{\max} - \frac{(\Omega_{\max} - \Omega_{\min})(H - H_{\text{aver}})}{H_{\max} - H_{\min}} \quad (2)$$

式中, H_{aver} 代表每代粒子的平均适配值; $H_{\min}$ 代表粒子群中适配值的最小值, H 代表微粒的适配值; $H_{\max}$, 代表粒子群中适配值的最大值; $\Omega_{\min}$ 为惯性系数的最小值, $\Omega_{\max}$ 为其最大值。在 ARIMA 的多项式系数优化问题中, $H_{\max}=0$, $H_{\min}=10$; $\Omega_{\min}=0$, $\Omega_{\max}=5$ 。

3 基于 BP 神经网络的股指时间序列建模

建模方法是通过神经的自学习能力, 对在一定时期内影响或反映 MA(10)时间序列的多个指标进行学习, 实现对 MA(10)的辨识和预测, 准确性与 BP 神经网络的结构设计相关。

3.1 输入层和输出层的选取

影响或反映 MA(10)时间序变化趋势的经济指标有很多, 其中: MA(5)能够反映市场的短线扰动对 MA(10)的影响; MA(20)能在更为宏观的层面反映市场的变化趋势; 考虑市场变化的连续性, 上一交易日的 MA(10)指数与下一个交易日关系密切; 宏观层面上, 汇率、CPI、工业增加值对 MA(10)影响较大, 微观层面上, 心理技术指标(PHY)对

MA(10)具有较高的参考价值。

基于以上考虑, 在本文输入层中, 应选取当天的 MA(5)指数 u_1 , 当天的 MA(20)指数 u_2 , 当天的 MA(10)指数 u_3 , 当天的汇率 u_4 , 当月的 CPI u_5 , 当月的工业增加值 u_6 及当天的心理技术指标收盘价 u_7 共 7 个神经元。输出层取 1 个神经元, 代表下一个股票交易日的 MA(10)指数 y 。

3.2 设计隐层

本节主要通过传递函数的选择和层数的确定来确定隐层的设计。

3.2.1 隐层数量

目前理论表明如果设计足够多的隐层神经元数目^[13], 则 BP 神经网络能够与任何具有有限间断点的非线性函数非常接近。针对预测股指时间序列, 本文采用 1 个隐层^[14]。

3.2.2 隐层传递函数

目前主要有 Sigmoid、正弦函数和三角型函数三种隐层神经元的传递函数。本文分别选用这三种传递函数训练得到的 3 种预测模型作为合作对策组合预测算法的单项预测模型。

3.3 BP 神经网络学习方式的设计

传统 BP 神经网络的核心学习方式动量法, 由于无法积累历史学习经验, 往往存在收敛缓慢甚至振荡的现象。因此本文采用动量法和自适应调整学习率作为 BP 算法的改进方法。

4 基于合作对策的组合预测

采用 ARIMA 和神经网络模型作为组合预测的单项预测模型。引入合作对策方法, 对两种算法进行组合预测, 实现“优势互补”。

4.1 合作目标选取

分别选用对称 Sigmoid 型、三角型、正弦函数三种函数建立 3 个神经网络预测模型, 和 ARIMA 建立的预测模型, 构成 $m=4$ 种单项预测方法, 称

为局中人^[15], 称 M 为组合预测方法的局中人集合。

第 i 种预测方法在第 t 时刻的预测值可由 $x_{it}, i=1, 2, \dots, m; t=1, 2, \dots, N$ 表示; 设 $l_1, l_2, \dots, l_m$ 为 m 种单项股指预测方法的加权系数, 那么可以得到第 t 时刻组合预测值为:

$$\hat{x}_t = l_1 x_{1t} + l_2 x_{2t} + \dots + l_m x_{mt} \quad (3)$$

加权系数必须满足如下条件:

$$l_1 + l_2 + \dots + l_m = 1, l_1, l_2, \dots, l_m \geq 0 \quad (4)$$

如果在第 t 时刻第 i 个单项预测方法的误差为 $e_{it} = (x_t - x_{it})$; 那么组合预测在第 t 时刻的预测误差为 e_t , 则有:

$$e_t = x_t - \hat{x}_t = \sum_{i=1}^m l_i e_{it} \quad (5)$$

本文采用合作联盟 M 进行组合预测, 其核心“利益”是为了降低股指时间序列预测误差。因此本文的合作联盟目标则可以设定为组合预测的误差平方和。有:

$$J(M) = \sum_{t=1}^N e_t^2 = \sum_{t=1}^N \sum_{i=1}^m \sum_{j=1}^m l_i l_j e_{it} e_{jt} \quad (6)$$

在 $J(M)$ 的基础上, 按合作对策方法从而确定组合测权系数, 建立组合预测模型。

4.2 合作权重计算

组合预测的关键是将各单项股指时间序列预测方法的加权系数确定^[16], 根据合作对策理论, 权重值应依照各局中人给联盟带来的贡献来分配。

$v(s)$ 表示 $J(s)$ 的相反数, 即 $v(s) = -J(s)$, 其中 s 为 M 的子集, 为 m 人对策的联盟成果, 可知 $v(M)$ 表示所有局中人参与时的最大联盟成果。第 i 个单项预测方法在合作联盟 s 中的“贡献”可以表示为 $v(s \cup \{i\} - v(s))$, 其中 $s \subset M$ 。

将最大联盟成果 $v(M)$ 中, 第 i 个单项预测方法的贡献分配表示为 $x_i, i=1, 2, \dots, m$, 则有:

$$\begin{aligned} x_1 &= v(\{1\}), \\ x_2 &= v(\{1, 2\}) - v(\{1\}), \\ x_3 &= v(\{1, 2, 3\}) - v(\{1, 2\}), \\ &\dots \\ x_m &= v(M) - v(M - \{m\}) \end{aligned} \quad (7)$$

由公式(7)可以知道, 单项预测算法的成果分配决定于局中人的编号, 如将局中人 $m, m-1, \dots, 2, 1$ 的编号改变成为 $1', 2', \dots, m'$, 那么就可以得到新的分配方案。

$$\begin{aligned} x'_1 &= v(\{m\}), \\ x'_1 &= v(\{m, m-1\}) - v(\{m\}), \\ &\dots \\ x'_m &= v(M) - v(M - \{1\}) \end{aligned} \quad (8)$$

由于本文采用了 4 种股指时间序列预测方法。局中人编号次序组合共有 $m! = 24$ 种, 即存在 24 种不同分配方案。合作策略理论中, 为了综合考虑不同分配方案, 局中人的最终“贡献”, 需要按照各局中人在各种编号排列下, 平均“贡献”值来计算。

设第 i 个局中人的平均“贡献”为 $\varphi_i(v)$, 则有:

$$\varphi_i(v) = \frac{1}{m!} \sum_{\tau} [v(s_{\tau}^i \cup \{i\}) - v(s_{\tau}^i)] \quad (9)$$

其中, τ 是由 $1, 2, \dots, m$ 组成的 m 级排列, $s_{\tau}^i = \{j | \tau j < i\}$ 代表排列 τ 中排在 i 前面的局中人组成的联盟。满足 $s_{\tau}^i = s$, 公式(9)可以进一步表示为:

$$\varphi_i(v) = \sum_{i \in s} \frac{(m-|s|)! (|s|-1)!}{m!} [v(s) - v(s - \{i\})], i=1, 2, \dots, m \quad (10)$$

有文献证明表明合作的总成果为组合预测方法中各个单项预测方法的平均贡献之和^[17], 即:

$$\sum_{i=1}^m \varphi_i(v) = v(m) \quad (11)$$

第 i 种预测方法的加权系数由平均贡献决定。因此本文采用公式(11)对 $\varphi_i(v)$ 进行归一化处理, 获取第 i 种单项预测方法的加权系数。

$$l_i = \frac{v(M)}{\varphi_i(v)} \bigg/ \sum_{j=1}^m \frac{v(M)}{\varphi_j(v)}, i=1, 2, \dots, m \quad (12)$$

4.3 实施步骤

合作策略组合预测中, 单项股指时间序列预测方法系数按照如下计算步骤进行计算:

Step 1 在初始状态下, 分别对 m 种单项预测方

法的对应的加权系数 $l_1, l_2, \dots, l_m$ 进行估计, 以解决权重系数未知, 特征函数和平均贡献率无法计算的问题。

设 $E = (\sum_{i=1}^N e_{ij} e_{ji})_{N \times N}$, 为误差信息矩阵, 估计

组合预测权系数的初始值时, 可以利用矩阵 E 对角线元素和均方差倒数方法进行, 构建初步的合作策略如下:

$$\hat{x} = l'_1 x_{1t} + l'_2 x_{2t} + \dots + l'_m x_{mt} \quad (13)$$

Step 2 利用公式(9), 结合预估合作策略(13), 计算各种联盟合作的特征函数。

Step 3 根据公式(8)对各个单项预测方法的平均分配“贡献”进行计算。

Step 4 组合预测权系数根据公式(10)对各个单项预测所获得的平均分配做归一化处理, 计算得到。

5 仿真分析

为了验证本文模型的有效性, 选取的股指样本为2003年9月-2013年2月上证综合指数各交易日的MA(10)作为数据, 采用matlab工具, 进行实证仿真分析。其中为了验证方法的有效性, 本文选取了1951组数据作为学习样本, 测试实验样本为后50组数据。

5.1 ARIMA 预测模型仿真实验

通过所采集的样本数据, 差分阶 $d=2$ 通过ARIMA 计算确定, 通过对ARIMA 结构进行分析, 依据BIC 原则, 选取 $p=4, q=3$, 从而确定ARIMA (4,2,3)结构, 因此在PSO 优化的过程中, 共需确定7个多项式系数, 根据matlab 仿真实验, 进行9次迭代计算后, 基本达到收敛位置。图2所示为预测模型误差对比曲线。




图2 预测模型误差对比曲线

Fig. 2 Prediction model error contrast curve

5.2 神经网络预测模型仿真实验

基于上述分析, 本文采用6-10-1的神经网络结构, 以2003年9月-2013年2月的上证综合指数的MA(5)指数 u_1 , MA(10), 指数MA(20)指数, 汇率, 当月的CPI, 当月的工业增加值, 心理技术指标为输入, 辨识MA(10), 采用常见的对称Sigmoid型传递函数进行建模。其结果如图3所示。




图3 对称Sigmoid型传递函数预测结果

Fig. 3 Prediction results of symmetric Sigmoid transfer function

从图3可以得出, 在一定时间范围内, 神经网络算法能够对MA(10)与多种金融指标之间的内在联系和因果关系进行辨识, 而不同的神经网络传递函数, 对结果有一定的影响。在一定程度上, 建模

结果反应了 MA(10)时间序列的变化趋势, 对比之下, 在辨识股指时间序列的局部波动时, ARIMA 效果更好, 但因为神经网络算法依赖于传递函数, 刻画金融数据时, 有一定的局限性, 精度有待进一步提高。

5.3 合作对策组合预测模型仿真实验

本文采用合作策略将多个单项预测模型进行组合, 可以综合神经网络预测模型和 ARIMA 预测模型的优势, 提高预测精度。

预测“联盟”包含了 ARIMA 建立的预测模型和 3 种神经网络预测模型。按照本文算法进行计算, 得到“联盟”最大成果 $v(M) = -2.5412$, 根据“平均贡献”计算各个模型的权重因子, 分别为 $l_1 = 0.257\ 425\ 743$, $l_2 = 0.227722772$, $l_3 = 0.207\ 920\ 792$, $l_4 = 0.306\ 930\ 693$ 。

图 4~6 分别是本文方法与广泛应用的 GARCH 模型、神经网络模型和 ARIMA 组合模型对比仿真结果图。




图 4 本文算法与 GARCH 预测结果图

Fig. 4 The prediction result map between the algorithm of this paper and the of GARCH prediction




图 5 本文算法与神经网络模型预测结果图

Fig. 5 The prediction result map between the algorithm of this paper and the neural network mode




图 6 本文算法与 PSO 优化的 ARIMA 组合模型预测结果图

Fig. 6 The prediction results of between the algorithm of this paper and the ARIMA combined PSO optimization

通过对数据进行分析预测, GARCH 模型的预测误差达到了 10%, 而本文本文的组合预测方法综合运用了 ARIMA 和神经网络方法的优点, 能够较好地预测预测股指趋势, 其预测误差仅为 2.68%, 而由此可知, 该预测模型的辨识效果不错。主要原因是合作对策算法能够结合神经网络对多维数据分析能力和 ARIMA 对主要趋势的辨识能力, 实现两种单项预测模型的“优势互补”, 大幅度的提升了模型的预测精度。

通过引入均方根误差评价指标 RMSE、股指分

析常用的平均绝对误差 MAE、趋势准确率指标 F 等几种方法对模型进行评价,可以验证本文算法的有效性。

从表 1 的结果可以看出,通过分析 50 个交易日的预测数据,在 RMSE、MAPE 和 F 三项指标方面,本文算法具有较好的拟合能力,优于单一的 GARCH 以及 PSO 优化的 ARIMA 组合模型预测算法,能够较好的跟踪股市情况。本文算法对未来具有很好的判断能力,因其 50 次趋势正确,正确趋势 45 次,准确率为 90%。因此本文算法能较好的跟踪上证综合指数的趋势。

表 1 常见算法指标对比结果

Tab. 1 Comparison result of common algorithm index

选择模型	MAE	RMSA	F
GARCH	11%	60.3	64.2
神经网络模型	6.75%	58.4	59.3
PSO 优化的 ARIMA 模型	7.64%	56.5	58.2
本文算法	2.68	23.3	90.0

6 结论

通过对股指时间序列自身特点的分析,并针对金融市场中存在的众多干扰因素,及其呈现的非线性和时变性,本文提出了基于合作对策的股指时间序列智能组合预测方法。

利用 ARIMA 对非平稳时间序列的分析能力,从时间关联性的角度出发,辨识股指时间序列的发展趋势,同时采用 PSO 算法解决 ARIMA 的多项式系数估计问题。以多种经济指标之间的相关性为出发点,利用神经网络方法,辨识股指时间序列的变化发展规律。为取长补短,实现“优势互补”,达到组合预测的目的,本文根据有关合作策略的理论,分配各个单一预测方法的权重系数。

本文通过实证分析的结果,采用组合预测的方法,组成新的预测算法,其中,新算法利用了侧重于空间和时间关联性的两种单项预测算法。一段时期内股指时间序列数据能通过该算法较好的精度拟合,模型精度比各三项预测模型有了较大提升。

参考文献:

- [1] Benjamin Graham, David Dodd. Security Analysis[M]. 北京: 人民大学出版社, 2013: 15-20.
Benjamin Graham, David Dodd. Security Analysis[M]. Beijing: China renming university press, 2013: 15-20.
- [2] 杨德勇. 证券投资学[M]. 北京: 中国金融出版社, 2010: 25-40.
Yang Deyong, Wang Shoufa. Research on Ecological Investment and Financing[M]. Beijing: China Financial press, 2010: 25-40.
- [3] 刘晓倩, 周勇. 金融风险管理中 ES 度量的非参数方法的比较及其应用[J]. 系统工程理论与实践, 2011, 26(4): 53-57.
Liu Xiaoqian, Zhou Yong. Comparison and Application of Nonparametric Methods for ES Measurement in Financial Risk Management[J]. Systems Engineering-Theory & Practice, 2011, 26(4): 53-57.
- [4] 曹松涛. 宏观基本面与股票市场的可预测性[J]. 前沿, 2012, 36(18): 52-56.
Cao Songtao. Macroeconomic fundamentals and predictability of stock market[J]. Forward Position, 2012, 36(18): 52-56.
- [5] 马春光, 吴冲锋, 倪苏云. 中国股票市场信息机构及实证研究[J]. 系统工程学报, 2003, 18(6): 530-534.
Ma Chunguang, Wu Chongfeng, Ni Suyun. Information Institutions and Empirical Research on Chinese Stock Market[J]. Journal of Systems Engineering, 2003, 18(6): 530-534.
- [6] 马思齐, 马刚. 股票市场风险、收益与市场效率: ARMA-ARCH-M 模型[J]. 世界经济, 2003, 18(5): 19-28.
Ma Siqi, Ma Gang. Stock market risk, return and market efficiency: ARMA-ARCH-M model[J]. World Economy, 2003, 18(5): 19-28.
- [7] 李民. 用 ARIMA 模型预测深沪股市[J]. 长沙铁道学院学报, 2000, 20(1): 78-84.
Li Min. Prediction of Shenzhen and Shanghai Stock Markets Using ARIMA Model[J]. Journal of Changsha Changsha Railway Institute, 2000, 20(1): 78-84.
- [8] 郑晓阳, 仲崇雨. ARIMA-GARCH 随机收益过程下幂型交换期权定价[J]. 哈尔滨工程大学学报, 2011, 32(3): 45-48.
Zheng Xiaoyang, Zhong Chongyu. Pricing of power-type exchange options under ARIMA-GARCH stochastic revenue process[J]. Journal of Harbin Engineering University, 2011, 32(3): 45-48.
- [9] 赵蕾, 陈美英. ARIMA 模型在福建省 GDP 预测中的应

- 用[J]. 科技和产业, 2007, 18(7): 39-12.
- Zhao Lei, Chen Meiyang. Application of ARIMA Model in GDP Forecast of Fujian Province[J]. Science & Technology, 2007, 18(7): 39-12.
- [10] 宋海礁. ARIMA 模型在上海市 GDP 预测中的应用[J]. 科教文汇(上旬刊), 2008, 23(8): 56-59.
- Song Haijiao. Application of ARIMA Model in GDP Forecast of Shanghai City[J]. Science, Education and Culture, 2008, 23(8): 56-59.
- [11] 胡旺, 李志蜀. 一种更简化而高效的粒子群优化算法[J]. 软件学报, 2007, 21(4): 71-75.
- Hu Wang, Li Zhishu. A simpler and more efficient particle swarm optimization algorithm[J]. Acta Scientiae Sinica. 2007, 21(4): 71-75.
- [12] 孟栋, 樊重俊, 刘思. 混沌粒子群神经网络在上证指数预测中的应用[J]. 数学理论与应用, 2014, 22(5): 92-95.
- Meng Dong, Fan Chongjun, Liu Si. Application of Chaos Particle Swarm Neural Network in Shanghai Stock Index Prediction[J]. Mathematic Theory and Applications, 2014, 22(5): 92-95.
- [13] 曾艳姗, 李仲飞. 基于粒子群优化算法的均值-VaR 投资组合选择[J]. 中山大学学报, 2012, 26(9): 87-89.
- Zeng Yanshan, Li Zhongfei. Mean-VaR Portfolio Selection Based on Particle Swarm Optimization[J]. Journal of Sun Yatsen University, 2012, 26(9): 87-89.
- [14] 冯健, 邱苑华. 一种基于信息熵的金融数据神经网络分类方法[J]. 控制与决策, 2012, 18(8): 61-65.
- Feng Jian, Qiu Yuanhua. A Financial Data Neural Network Classification Method Based on Information Entropy[J]. Control and Decision. 2012, 18(8): 61-65.
- [15] 刘家河, 金秀, 陈露艳. 基于IDNPSO-BP神经网络的股票市场指数预测[J]. 东北大学学报, 2013, 25(7): 95-99.
- Liu Jiahe, Jin Xiu, Chen Luyan. Prediction of Stock Market Index Based on IDNPSO-BP Neural Network[J]. Journal of Northeastern University, 2013, 25(7): 95-99.
- [16] 黄安强, 肖进, 汪寿阳. 一个基于集成情境知识的组合预测方法[J]. 系统工程理论与实践, 2011, 25(7): 113-117.
- Huang Anqiang, Xiao Jin, Wang Shouyang. A Combination Forecast Method Based on Integrated Situation Knowledge[J]. Systems Engineering - Theory & Practice, 2011, 25(7): 113-117.
- [17] 韩卫彬, 孙浩, 王文文. 收益模糊合作对策 Shapley 值的公理化[J]. 模糊系统与数学, 2012, 12(2): 32-36.
- Han Weibin, Sun Hao, Wang Wenwen. Axiomatization of Shapley Values for Fuzzy Cooperative Measures[J]. Fuzzy Systems and Mathematics, 2012, 12(2): 32-36.
- [18] 孟凡永, 张强, 孙红霞. 模糊合作对策上的 Banzhaf 函数[J]. 系统工程学报, 2012, 24(1): 89-93.
- Meng Fanyong, Zhang Qiang, Sun Hongxia. The Banzhaf Function on Fuzzy Cooperative Games[J]. Journal of Systems Engineering, 2012, 24(1): 89-93.

《系统仿真学报》荣获“2017 中国国际影响力优秀学术期刊”证书

由中国学术期刊（光盘版）电子杂志社与清华大学图书馆联合成立的中国学术文献国际评价研究中心，发布了 2017 版《中国学术期刊国际引证年报》，《系统仿真学报》荣获“2017 中国国际影响力优秀学术期刊”。

《年报》（2017 版）采用的统计源期刊为 20192 种，涵盖 WoS 收录的 SCI 期刊 8874 种、SSCI 和 A&HCI 期刊 4645 种，ESCI 期刊 5578 种；增补期刊 1762 种。参照中外文学学术期刊总被引频次、影响因子、半衰期等各项国际引证指标，计算期刊影响力指数(CI)，对国内 6210 种学术期刊排序，遴选了人文社科、自然科学与工程技术两个类别的 TOP10%为国际影响力品牌学术期刊。TOP5%以内的期刊为“最具国际影响力学术期刊”、TOP5-10%之间的为“国际影响力优秀学术期刊”。