

# 基于模式识别与贝叶斯决策的股票市场短期趋势预测模型

王彩霞<sup>1</sup>, 王荣全<sup>2</sup>

(1.外交学院 国际经济学院, 北京 100037; 2.北京科技大学 计算机与通信工程学院, 北京 100083)

**摘要:**文章基于1990—2022年上证综合指数收盘价数据,运用模式识别、模式匹配和贝叶斯决策对我国股票市场短期趋势进行研究。结果表明:随着社会的发展,股票市场对于相似影响因素的响应时间缩短。对我国股票市场进行模式识别和模式匹配时,锁步度量比弹性度量更灵活,效果更稳定。此外,时间窗的选择会影响趋势分析的准确性,时间窗过小模式中信息含量较少,时间窗过大模式中噪音较多,因此在模式识别和模式匹配时要设置合理的时间窗。最后,本文建立了基于模式识别和贝叶斯决策的股指短期趋势预测模型。该模型综合考虑了所有高度相似历史模式的趋势,再结合当前模式的特征对未来股指趋势进行分析和预测,因此模型有很强的解释性,且实验结果比传统的模式识别预测模型有了显著提升。

**关键词:**股票价格指数;模式匹配;模式识别;贝叶斯决策;趋势预测

**中图分类号:**F830.91

**文献标识码:**A

**文章编号:**1002-6487(2024)24-00

## 0 引言

股票价格指数(股指)趋势的研究一直都是投资者、金融监管部门、研究人员极其关注的问题,也是极具挑战性的问题。无论是建立投资组合获取超额收益,还是探寻股指收益率的分布规律,或是分析股市的潜在风险,都离不开对股指趋势的研究。一些学者的研究表明,股市的变化本质上就是一种随机游走,所以试图预测股票市场价格趋势的变化是枉然的,其中最具标志性的是尤金·法马的有效市场假说。但是 Andrew 和 MacKinlay (1988)<sup>[1]</sup>的研究表明,股票市场价格不是简单遵循随机游走,如 Scheinkman 和 LeBaron (1989)<sup>[2]</sup>在股票收益的变化中发现了混沌现象,这种看似无序实则有序的混沌现象,解释了股票市场分析 and 预测的可行性。

股指数据是显著的非平稳、高波动、极复杂的数据。目前,股指分析和预测主要集中在基本面分析、技术分析、演化分析、采用智能计算进行分析四个方面。传统的技术分析、统计模型或单一的机器学习方法很难获得理想的趋势分析和预测结果。但是随着知识理论的发展与技术、方法的革新,越来越多更有效、更智能的股指趋势预测方法应运而生<sup>[3,4]</sup>。人工神经网络凭借其强大的非线性拟合能力,在股指趋势预测领域也得到了广泛应用,很多学者和研究人员利用各种神经网络预测股票价格或股指趋势<sup>[5]</sup>。神经网络复杂的结构特性使其具有较好的拟合效果,但是这种结构的复杂性也给研究人员带来了一系列挑战,其中

最大的挑战就是模型的不可解释性。

智能计算法是通过模仿人类思维来处理现实中的复杂问题,特别是利用人工智能、机器学习等领域的理论和方法对股指趋势进行预测<sup>[6]</sup>。股票价格某种程度上是投资者群体决策的结果,股指趋势体现了投资者群体行为和情绪变化,因此股票市场会出现相似的模式或趋势。基于此,一些研究人员采用模式识别和模式匹配技术进行股票价格或股指预测<sup>[6,7]</sup>。也有一些学者尝试将贝叶斯理论应用于股票价格涨跌或股指趋势预测<sup>[8,9]</sup>。相比之下,国内利用模式识别、模式匹配和贝叶斯理论研究股票价格或股指趋势的成果较少。因此,本文在模式识别和模式匹配的方法之上融合贝叶斯决策理论,针对我国股指数据特点,构建一种新的股指趋势预测方法。

## 1 理论基础与模型构建

### 1.1 理论基础

技术分析的三大前提假设是:(1)市场行为涵盖一切信息;(2)价格沿趋势演变;(3)历史往往会重演。股指趋势能够度量和反映股票市场总体价格水平及变动趋势。相对个股而言,股指的变化相对稳定,它受到市场综合因素的影响,且依赖趋势变化的特征明显。螺旋式上升的模式不仅体现在人类发展史上,在投资决策中参与者也会因为利益的驱使或是对风险的恐惧,以及认知结构的变化,导致在投资决策时出现螺旋式上升的模式,从而呈现股指变化的“历史重演”,而经济发展的周期性现象也从现实上

**基金项目:**中央高校基本科研业务费专项资金青年教师科研启动基金项目(重点项目)(3162022ZYQA01)

**作者简介:**王彩霞(1983),女,吉林舒兰人,博士,副教授,研究方向:金融数据分析与挖掘。

(通讯作者)王荣全(1992—),男,吉林舒兰人,博士,讲师,研究方向:图结构学习、计算机视觉。

和理论上支撑了股市的“历史重演”。这是基于模式识别和模式匹配进行股指趋势研究或预测的基础。

## 1.2 模型构建

### 1.2.1 模式识别

设第  $t$  天的股指收盘价为  $i_t$ , 忽略停牌期间的时间间隔, 第  $t$  天的股指涨跌为  $\Delta i_t = i_t - i_{t-1}$ , 第  $t$  天的股指收益率为  $r_t = \Delta i_t / i_{t-1}$ 。将所有股指样本点表示为  $\{i_1, i_2, i_3, \dots, i_n\}$ , 其中,  $i_1$  为第一个股票价格指数,  $i_n$  为第  $n$  个股票价格指数。如果设时间窗为  $T$ , 那么全体样本点所构成的历史模式有  $n-T$  个, 这  $n-T$  个模式就构成了历史模式的样本空间, 记为  $Pattern = \{I_1, I_2, I_3, \dots, I_{n-T}\}$ , 其中第  $k$  个历史模式为  $I_k = \{i_k, i_{k+1}, \dots, i_{k+T-1}\}$ , 而当前模式为:

$$I_N = I_{n-T+1} = \{i_{n-T+1}, i_{n-T+2}, \dots, i_{n-T+T}\} \quad (1)$$

图1是利用模式识别和模式匹配进行股指趋势分析的一个示意图。其中, 图1(a)为上证综合指数收盘价5000个点的时序图(2002年3月至2022年9月), 为了更直观地展示利用模式识别进行股指预测的方法, 取时间窗  $T=150$ ; 图1(c)为当前模式  $I_N$ ; 图1(b)为样本空间中基于皮尔逊相关系数匹配到的最相似的历史模式。基于“历史重演”的思想, 利用最相似历史模式对当前模式的趋势进行分析和预测。图1(b)和图1(c)中的“·”是最相似历史模式和当前模式的最后一个时间点的股指位置; 图1(b)中的“\*”是最相似历史模式下一个时间点的股指位置, 它表示了历史模式的趋势, 由“历史重演”可知, 当前模式与最相似历史模式的趋势具有一致性; 图1(c)中“\*”是利用最相似历史模式预测出来的下一个时间点的股指位置, 而图1(c)中“+”是当前模式下一个时间点的真实位置。从图1可以看出, 此次基于模式识别预测的股指趋势与真实股指趋势是一致的。




图1 基于模式识别与模式匹配的股指趋势预测示例

时间序列(时序)在模式识别过程中非常关键的一步就是确定时间窗  $T$ , 时间窗  $T$  的取值不同, 模式中所包含的股指信息就不同, 可以说模式识别的时间窗承载了模式中所呈现的特征与趋势信息。因此, 能否正确地选择时间窗  $T$  是能否准确提取模式的关键。本文实证分析中一个重要的任务是通过实验对比确定我国股票市场股指能够呈现模式的时间窗。

### 1.2.2 模式匹配

在基于时域的时序数据中, 度量两个时序相似性的方法有很多, 经典的时序相似性度量方法大致被分为两类,

即锁步度量和弹性度量。锁步度量指的是将当前模式与历史模式进行一对一比较, 相似性度量方法有欧氏距离、曼哈顿距离、闵可夫斯基距离、余弦相似度、皮尔逊相关系数等。弹性度量允许当前时间窗的时序与历史模式的时序进行一对多(或多对一)的比较, 例如, 动态时间规整(DTW)、基于编辑距离的度量等。

设当前模式  $I_N = \{i_{n1}, i_{n2}, \dots, i_{nT}\}$ , 历史模式  $I_M = \{i_{m1}, i_{m2}, \dots, i_{mL}\}$ , 锁步度量是一对一的计算两个长度相同的时序( $T=L$ )。而弹性度量可以计算两个长度不同的时序, 即  $T \neq L$ , 它通过时序片段的放缩进行对齐, 从而看上去像是通过扭曲对应的方式进行相似性计算, 因此可以存在一对多或者多对一的对齐。弹性度量方法中应用最为广泛的是动态时间规整(DTW), DTW 是1957年由日本学者 Itakura 提出的相似性度量方法。DTW 通过寻找一个最优的对应  $R(I_N, I_M) = \{(i_{n1}, i_{m1}), \dots, (i_{nk}, i_{mj}), \dots, (i_{nT}, i_{nL})\}$ , 使得在这条路径上的距离最小。  $R$  上的距离计算公式如下:

$$d_R(I_N, I_M) = \sqrt{(i_{n1} - i_{m1})^2 + \dots + (i_{nk} - i_{mj})^2 + \dots + (i_{ns} - i_{mt})^2 + \dots + (i_{nT} - i_{mL})^2} \quad (2)$$

其中,  $1 \leq k \leq s \leq T, 1 \leq j \leq t \leq L$ 。每个从起点  $(i_{n1}, i_{m1})$  到终点  $(i_{nT}, i_{mL})$  的对映都可以计算出一个  $d_R(I_N, I_M)$  值, 而其中最小的  $d_{\min}(I_N, I_M)$  即为最优路径。两段时序的  $d_{\min}(I_N, I_M)$  越小, 说明两个时序越相似, 也就是越匹配。锁步度量的方法相对更容易计算, 时间复杂度低, 而基于弹性度量方法在样本较少时有较高的效率且相对更精确。因此, 本文另一个重要的任务是通过实验对比分析确定哪种度量方式更适合我国股票市场。

### 1.2.3 预测模型

如果与当前模式  $I_N = \{i_{n-T+1}, i_{n-T+2}, \dots, i_n\}$  高度相似的历史模式为  $I_j = \{i_j, i_{j+1}, \dots, i_{j+L_j-1}\}$ 、 $I_k = \{i_k, i_{k+1}, \dots, i_{k+L_k-1}\}$ 、 $I_s = \{i_s, i_{s+1}, \dots, i_{s+L_s-1}\}$  等, 那么接下来的任务就是如何有效地利用这些相似模式对当前模式的趋势进行分析和预测。本文最后的研究重点在于如何利用挖掘出的相似历史模式对当前模式的未来趋势进行分析和预测。当前模式下一个时间点的趋势模型如式(3)所示:

$$trend_{n+1} = f(I_j, I_k, I_s, \dots) \quad (3)$$

其中,  $f$  是相似历史模式的趋势向当前模式未来趋势的投影法则。

## 2 实证研究

### 2.1 数据来源

本文选取了自1990年12月19日至2022年9月30日中国上证综合指数日收盘价, 约7700个数据点, 数据源于WIND数据库。样本空间中所含的历史模式越丰富, 能从历史模式中挖掘到与当前模式相匹配的模式概率越大, 可参考的发展趋势也越多, 从而对当前模式的趋势分析和预

测越有利。虽然股指数据很多,但是收盘价对于股指趋势的研究至关重要。一方面收盘价与未来的趋势最接近、时效性最强;另一方面,收盘价是市场参与者在买方和卖方多方博弈后都能接受的价格。因此,在股指趋势研究中收盘价数据是首选。

图2(a)是中国上证综合指数日收盘价的时序图。为了使历史模式更丰富,结合实验的需要选定其中约前99%的数据作为样本集,余下约1%作为测试集。从上证综合指数时序图2(a)和股指收益时序图2(b)中可以发现,上证综合指数是一个具有波动聚集性的非平稳时序。从股指收益率分布图2(c)中可以观察到,我国股指收益率分布具有显著的尖峰厚尾性。




图2 上证综合指数及其收益和收益率时序图

## 2.2 模式匹配方法的选择

考虑到投资者认知的螺旋式上升模式,且投资者对相近经济状况、国际环境、极端事件的响应时间会有所不同,因此股指的动态趋势模式可能有时间跨度上的差异,也就是当前模式与历史模式在时间跨度上可能会存在快进或放慢。虽然从定性的分析上弹性度量方法在模式相似度的匹配结果上应该更具优势,但是目前由于弹性度量方法,如DTW在计算模式之间的相似性时主要基于欧式距离,而股指时序数据的数值较大,因此相似性的计算结果与时序之间实际形态相似性会存在较大差异,从而使结果不稳定。例如,在数据中取测试集 $N=100$ ,其余为历史模式。当前模式的时间跨度 $T$ 取3,5,7,9,10,历史模式的时间跨度 $W$ 取1至10时,利用DTW的模式匹配方法对测试集中100个当前模式进行趋势分析,其结果如图3所示。

如图3所示,利用DTW进行模式匹配时,当前模式时间窗 $T=3$ 时,预测效果中最佳的历史模式时间窗为 $W=4$ ;当前模式时间窗 $T=5$ 时,预测效果中最佳历史模式的时间窗为 $W=5$ ;而当前模式时间窗 $T=7$ 时,预测效果中最佳历史模式的时间窗为 $W=10$ 。可见基于DTW的模式匹配在股指趋势预测中,其结果不具有统一性,预测准确率在50%左右,效果也不显著。但是从整体上来看,当前模式的时间窗小于或等于历史模式的时间窗时,趋势分析结果相对较好。这表明,随着投资者智慧的提升、知




图3 当前模式 $T=3,5,7,9,10$ ,历史模式 $W=1\sim10$ 时,基于弹性度量DTW的股指趋势预测结果

识的拓展、科学技术的发展,投资者在股市投资过程中对于股票价格的影响因素或信息的响应时间缩短了。

图4为基于DTW进行模式匹配预测效果最佳的情况。此时当前模式时间窗 $T=5$ ,历史模式时间窗 $W=5$ 。图4(a)为100个测试模式的预测值(虚线)与真实值(实线)的时序图,图4(b)为预测值与真实值的偏离,图4(c)是趋势预测结果的统计图。此时,基于弹性度量DTW的趋势分析结果中最好情况下,错误率 $False=36\%$ ,正确率 $True=64\%$ 。




图4 当前模式 $T=5$ ,历史模式 $W=5$ 时,基于DTW的股指趋势预测结果

与弹性度量相比,锁步度量中相似性的度量方法更丰富,由于相似性的度量角度不同,匹配到的结果差异性也很大,其中应用比较广泛的是欧式距离、余弦相似度和皮尔逊相关系数。图5是时间窗 $T$ 从2到20时,基于欧式距离、余弦相似度和皮尔逊相关系数的趋势分析效果图。如图5所示,若时间窗 $T$ 取值较小( $T\leq 6$ )时,模式中所含信息有限,三种相似性度量方法的预测效果均不显著,也不具有一致性。随着时间窗的取值增大( $T>6$ ),模式中含有丰富的位置、收益率、波动性、发展趋势等信息,此时基于皮尔逊相关系数的分析结果比余弦相似度和欧式距离相对稳定,而且几乎保持着优势。通过定性分析和实验结果对比可知,与弹性度量相比,锁步度量的计算复杂度低,时间成本低,效果相对稳定,尤其是基于皮尔逊相关系数的锁步度量整体效果较好,因此本文模式匹配选择的是基于皮尔逊相关系数的锁步度量。

## 2.3 时间窗的选择

时间窗的选取会影响到模式匹配的结果,从而对股指趋势的分析产生影响。时间窗 $T=1$ 的模式中呈现了股指的位置,反映的是股票市场总体价格水平的高低。时间窗 $T=2$ 的模式中除了含有股票市场的总体价格水平






图5 基于欧式距离、余弦相似度、皮尔逊相关系数的股指趋势预测结果

外,还包含了相邻时间点的股指涨跌趋势和幅度。而 $T=3$ 的模式中即有总体价格水平、涨跌趋势和幅度,还包含了涨跌的速度,速度越快,说明市场涨跌的趋势越强劲。由此可见,时间窗 $T$ 取值越大,模式中所含的信息越多,但是如果时间窗 $T$ 取值过大,意味着时序中的噪音过多。显然时间窗的选取太短或太长都不利于股指趋势研究。

图6是基于皮尔逊相关系数的模式匹配实验,并利用匹配到的最相似历史模式趋势分析当前模式的趋势,其中测试模式 $N=100$ 。从实验结果上来看,时间窗的选择影响了趋势分析的准确性,如果时间窗太短(如 $T \leq 6$ ),那么此时模式中所含信息量不足,所以预测效果不佳;如果时间窗太长(如 $T \geq 30$ ),那么此时模式中所含噪音太多,因此分析结果也会变得糟糕。事实上,每个阶段股票市场所对应的股票、投资者能力、市场环境、交易规则、国际环境等都可能有很多不同,这导致每个阶段股票市场形成模式的时间窗也会不同。如图6所示,如果以最相似的历史模式进行趋势预测,那么这100个测试集对应的时间段内预测效果最佳的时间窗是 $T=25$ 。




图6 时间窗 $T=2 \sim 40$ ,测试集 $N=100$ 时,不同时间窗下股指趋势预测结果

#### 2.4 股指趋势预测模型

如果当前模式 $I_N = \{i_{n-(T-1)}, i_{n-(T-2)}, \dots, i_n\}$ ,那么通过模式匹配挖掘出与 $I_N$ 相似度超过阈值 $\theta_0$ 的历史模式只有 $I_k$ 一个,记 $\text{Similarity}(I_N, I_k) \geq \theta_0$ 。不妨设历史模式为 $I_k = \{i_k, i_{k+1}, \dots, i_{k+(T-1)}\}$ ,那么当前模式下一个时间点的位置为 $i_{n+1} = \frac{i_{k+T}}{i_{k+(T-1)}}$ ,因此当前模式 $I_N$ 第 $n+1$ 天的趋势预测模型如式(4)所示:

$$\text{trend}_{n+1} = \begin{cases} 1, & i_{n+1} > i_n \\ 0, & i_{n+1} = i_n \\ -1, & i_{n+1} < i_n \end{cases} \quad (4)$$

其中,1表示股指在下一个交易日上涨,0表示股指在下一个交易日不变,而-1则表示股指在下一个交易日下跌。如果与当前模式 $I_N$ 相似度超过阈值的历史模式有 $m$ 个,那么通过模式匹配挖掘的所有相似历史模式为 $I_{N,m} = \{I_{k,1}, I_{j,2}, \dots, I_{l,m}\}$ ,其中, $I_{k,1}$ 为第一个高度相似模式, $I_{j,2}$ 为第二个高度相似模式, $I_{l,m}$ 第 $m$ 个高度相似的模式。根据这些历史模式的已有态势建立基于贝叶斯决策理论的第 $n+1$ 天趋势预测模型,如(5)所示:

$$\text{trend}_{n+1} = \begin{cases} 1, & P_{up} > P_{down} \\ 0, & P_{up} = P_{down} \\ -1, & P_{up} < P_{down} \end{cases} \quad (5)$$

其中, $P_{up} = p(i_{s+T} > i_{s+(T-1)}, s \in \{k, j, \dots, l\})$ ,而 $P_{down} = p(i_{s+T} < i_{s+(T-1)}, s \in \{k, j, \dots, l\})$ , $p$ 表示股指涨跌概率。

根据模型假设可知,如果所有的历史模式与当前模式的相似度都没有超过阈值,那么不能强行选择相似度相对最高的历史模式来进行趋势研究,因为没有“历史重演”的基础。当然相似性阈值不同也会导致可参考的趋势不同,从而影响贝叶斯决策的分析结果。如图7(a)所示,选取10个测试模式作为当前模式,以 $T=9$ 为例,股指趋势预测模型的准确率随着阈值 $\theta$ 变化。事实上,阈值 $\theta$ 的取值不同导致了匹配到的相似历史模式不同,因此基于相似历史模式而建立的趋势预测模型的结果也不同。从图7(a)可以发现,当 $\theta < 0.5$ 时,由于阈值设置较低使得相似度的标准过低,此时模式匹配会将一些差异性很大的历史模式作为与当前模式“形似”模式,而这些历史模式实际上与当前模式不具有“历史重演”的基础,因此趋势分析效果不佳。当 $\theta > 0.9$ 时,由于阈值设置太高使得匹配过程中漏掉了跟当前模式有共同发展态势的一些历史模式,因此降低了股指趋势预测结果。利用最相似历史模式进行股指趋势分析和预测至少存在两个问题:一个是历史模式中的最相似模式可能与当前模式有很大差异,另外一个是用最相似模式进行预测实际上漏掉了一些与当前模式高度相似的其他历史模式的信息。图7(b)中,当 $T=9$ 时,传统的趋势预测模型准确率是50%;而在图7(c)中,当 $T=9, \theta_0=0.7$ 时,结合贝叶斯决策的趋势预测模型准确率为80%。

从实验结果来看,基于贝叶斯分类的趋势预测比传统的趋势预测结果好很多。在模式匹配过程中,对匹配结果进行筛选和综合考虑是必要的。只有当历史模式与当前模式的相似度达到一定程度时,其发展态势才更有助于研究当前模式的趋势。基于模式识别和贝叶斯决策的趋势分析不仅考虑了股票市场当前的状态,还综合考虑了类似环境下投资者的决策惯性,因此更具有解释性。

### 3 结果分析

股指趋势预测模型的评价最直接的方式就是计算准确率。模型准确率 $P$ 等于趋势预测正确的数据量(真正例 $TP$ 及真反例 $TN$ )除以总的验证数据量 $N$ ,计算公式




图7 阈值  $\theta$  对股指趋势预测结果的影响

如式(6)所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{TP + TN}{N} \quad (6)$$

以时间窗  $T=25$  为例,将 100 个测试模式进行分组对比实验,观察相似度阈值  $\theta$  与预测准确率  $P$  的关系。将  $\theta$  按照步长 0.05 取 20 个值分别进行实验,结果如图 8 所示。其中,图 8(a)最佳相似度阈值是  $\theta=0.65$ ,图 8(d)最佳相似度阈值是  $\theta=0.75$ ,而图 8(g)最佳相似度阈值是  $\theta=0.7$ 。从图 8 可以看出,如果相似度阈值设置较低 ( $\theta < 0.5$ ),那么模式匹配结果中包含了一些与当前模式差异性很大的历史模式,所以此时准确率相对较低。而当阈值设置较高 ( $\theta > 0.95$ ) 时,会漏掉非常有价值的信息,从而忽略了一些与当前模式有着共同发展态势的历史模式,这些历史模式实际上包含了投资者在相似市场环境下的惯性投资行为。总而言之,相似度阈值设置过低会使得模式匹配得到的结果含有太多干扰信息,即包含了許多不具有相同趋势的历史模式,从而影响了趋势预测结果;而阈值设置太高会使得匹配过程中漏掉与当前模式高度相似的历史模式,从而失去了“有价值的一票”。只有当相似度阈值控制在一定的范围内时,该模型的趋势分析准确率才会有显著的提升。从实验结果上来看,当时间窗  $T=25$  时,100 个测试模式的最佳相似度阈值  $\theta$  几乎聚集在 0.5~0.8,此时预测准确率平均在 65% 左右,最高的可以达到 90%。

#### 4 结束语

本文首先利用基于 DTW 的模式匹配对股指趋势进行分析,其结果表明当前模式的时间跨度小于或等于历史模式的时间跨度时,趋势预测效果相对更好。其次,通过对比实验发现,与弹性度量相比,锁步度量方法更灵活,计算复杂度低,时间成本低,结果相对稳定,尤其是基于皮尔逊相关系数的锁步度量更适合我国股指趋势的模式识别和模式匹配。再次,在模式识别过程中时间窗的选择尤为重要,太短或太长都会降低准确率,通常情况下,时间窗的选取不要小于 4 或者大于 30。最后,本文提出了一个新的基于模式识别和贝叶斯决策的股指趋势预测模型,该模型通




图8 取  $T=25$ , 将 100 个测试模式进行分组对比实验

过挖掘相似历史模式,利用贝叶斯决策理论对股指趋势进行分析和预测。实验结果表明,当前模式呈现一定特征时,且相似度阈值设置合适,模型分析的结果才会有较高的准确性。实际上,只有历史样本中的模式与当前模式的相似度大于阈值时,才能利用历史模式对当前模式的未来趋势进行分析和预测,从而指导决策。

#### 参考文献:

- [1]Lo W A, MacKinlay C A. Stock Market Prices do not Follow Random Walks: Evidence From a Simple Specification Test [J].The Review of Financial Studies,1988,1(1).
- [2]Scheinkman A J, LeBaron B. Nonlinear Dynamics and Stock Returns [J].The Journal of Business,1989,62(3).
- [3]耿立艳,郭斌.中国股指波动率的智能预测模型与实证检验[J].统计与决策,2016,(7).
- [4]许雪晨,田侃.一种基于金融文本情感分析的股票指数预测新方法[J].数量经济技术经济研究,2021,38(12).
- [5]Sharma D K,Hota H S,Brown K, et al. Integration of Genetic Algorithm With Artificial Neural Network for Stock Market Forecasting [J]. International Journal of System Assurance Engineering and Management,2021,(13).
- [6]Kumar G, Jain S, Singh P U. Stock Market Forecasting Using Computational Intelligence: A Survey [J].Archives of Computational Methods in Engineering,2020,28(3).
- [7]Cervelló-Royo R, Guíjarro F, Michniuk K. Stock Market Trading Rule Based on Pattern Recognition and Technical Analysis: Forecasting the DJIA Index With Intraday Data [J].Expert Systems With Applications,2015,42(14).
- [8]Cabrera G, Coronado S, Rojas O, et al. A Bayesian Approach to Model Changes in Volatility in the Mexican Stock Exchange Index [J].Applied Economics,2018,50(15).
- [9]Awan M J, Shafry M, Rahim M. Social Media and Stock Market Prediction: A Big Data Approach [J].Computers, Materials & Continua, 2021,67(2).

(责任编辑/梁 红)