



## Designing a Stock Recommender System Using the Collaborative Filtering Algorithm for the Tehran Stock Exchange

Marziyeh Nourahmadi

Ph.D., Department of Financial Engineering, Faculty of Economic, Management and Accounting, Yazd University, Yazd, Iran. E-mail: mnourahmadi@ut.ac.ir

Ali Rahimi

MSc., Department of Electrical Engineering, Faculty of Electrical Engineering, Amir Kabir University of Technology (Tehran Polytechnic), Tehran, Iran. E-mail: ali-rahimi@aut.ac.ir

Hojjatollah Sadeqi \*

\*Corresponding Author, Associate Prof., Department of Finance Management, Yazd University, Yazd, Iran. E-mail: sadeqi@yazd.ac.ir

### Abstract

#### Objective

With the increasing volume of information and the complexity of financial markets, investors are increasingly seeking innovative financial tools to make more informed decisions. These tools should help investors choose the right stocks and achieve better returns. In this regard, stock recommendation systems are becoming increasingly important. Stock recommendation systems can assist investors in achieving superior returns by selecting the right stocks. However, traditional stock recommendation systems often lack the necessary accuracy and efficiency. This research aims to develop a novel approach called Stock-based Collaborative Filtering to design a stock recommendation system for the Tehran Stock Exchange. This method is founded on two key assumptions: first, market inefficiency, meaning the stock market does not completely and accurately

**Citation:** Nourahmadi, Marziyeh; Rahimi, Ali & Sadeqi, Hojjatollah (2024). Designing a Stock Recommender System Using the Collaborative Filtering Algorithm for the Tehran Stock Exchange. *Financial Research Journal*, 26(2), 318-346. <https://doi.org/10.22059/FRJ.2023.360955.1007479> (in Persian)



reflect all available information; and second, the presence of hidden information in stock movements, indicating that these movements contain valuable insights that can influence the prices of other stocks in the market. In this research, assuming the existence of the transmission effect on the Tehran Stock Exchange, we used the collaborative filtering technique, a common algorithm in recommender systems, to design a stock recommender system. The purpose is to help investors select the best-performing stocks to outperform the market.

### Methods

This study uses historical stock price data of 145 firms listed on the Tehran Stock Exchange from 2012 to 2021. The collaborative filtering algorithm was implemented in two stages: training and testing. In the training stage, the algorithm was trained using data from 2012 to 2016, and in the testing stage, its performance was evaluated on data from 2016 to 2021. Following, buy and sell signals were generated using the stock-based collaborative filtering algorithm during the same period. Finally, the strategy was evaluated.

### Results

The algorithm was tested as an investment strategy in both in-sample and out-of-sample periods. The results obtained from the algorithm for the out-of-sample periods show that this strategy can achieve a 25-fold return. The overall index returned 16 times during this period, indicating the excellent performance of the strategy over time. Additionally, the value at risk (VaR) for the selected method during the study period stood at -12.8%, indicating the lower risk of this method.

### Conclusion

Stock-based collaborative filtering is an active investment strategy. This intelligent algorithm aims to identify undervalued stocks and achieve higher returns than the market. This algorithm can serve as a valuable tool for active investors seeking to identify valuable stocks and achieve higher returns than the market. Therefore, further research is necessary to examine the performance of this algorithm in different markets and diverse economic conditions. Also, it is recommended to implement risk control strategies and optimize the system's efficacy further.

**Keywords:** Recommender systems, Collaborative filtering, Stock selection, Transmission effect, Stock forecasting.

## طراحی سیستم توصیه‌کننده سهام مبتنی بر الگوریتم فیلترینگ مشارکتی برای بورس اوراق بهادار تهران

مرضیه نوراحمدی

دکتری، گروه مهندسی مالی، دانشگاه یزد، یزد، ایران. رایانامه: mnourahmadi@ut.ac.ir

علی رحیمی

کارشناس ارشد، گروه مهندسی برق، دانشکده مهندسی صنعتی امیرکبیر، تهران، ایران. رایانامه: ali-rehimi@aut.ac.ir

حجت الله صادقی \*

\* نویسنده مسئول، دانشیار، گروه مدیریت مالی، دانشگاه یزد، یزد، ایران. رایانامه: sadeqi@yazd.ac.ir

### چکیده

**هدف:** با افزایش حجم اطلاعات و پیچیدگی بازارهای مالی، سرمایه‌گذاران به طور فزاینده‌ای به دنبال ابزارهای نوین مالی، برای تصمیم‌گیری آگاهانه‌ترند. این ابزارها باید به سرمایه‌گذاران کمک کنند تا ضمن انتخاب سهام مناسب، بازدهی بیشتری کسب کنند. در این راستا، سیستم‌های توصیه‌کننده سهام، اهمیت بیشتری پیدا می‌کنند. سیستم‌های توصیه‌کننده سهام می‌توانند در این زمینه به سرمایه‌گذاران کمک کنند تا با انتخاب سهام مناسب، بازدهی بیشتری کسب کنند. سیستم‌های توصیه‌کننده سهام، اغلب دقت و کارایی لازم را ندارند. این پژوهش، روشنی نویی به نام فیلترینگ مشارکتی مبتنی بر سهام را برای طراحی سیستم توصیه‌کننده سهام در بورس اوراق بهادار تهران ارائه می‌دهد. این روش بر پایه دو فرضیه کلیدی بنا شده است: ۱. عدم کارایی بازار: بازار سهام به طور کامل کارآمد نیست و اطلاعات را به طور کامل و دقیق منعکس نمی‌کند. ۲. اطلاعات نهفته در حرکات سهام: حرکت سهام نوعی اطلاعات دارد و می‌تواند بر قیمت سهام دیگر در بازار تأثیر بگذارد. در این پژوهش با فرض وجود اثر انتقال در بورس اوراق بهادار تهران، از تکنیک فیلترینگ مشارکتی برای طراحی یک سیستم سهام توصیه‌کننده استفاده شده است که یکی از الگوریتم‌های سیستم‌های توصیه‌کننده به شمار می‌رود. هدف این استراتژی، یافتن سهام مستعد برای کسب بازدهی بیشتر از بازار است.

**روش:** در این پژوهش، از داده‌های تاریخی قیمت سهام ۱۴۵ شرکت حاضر در بورس اوراق بهادار تهران، در بازه زمانی ۱۳۹۱ تا ۱۴۰۰ استفاده شد. الگوریتم فیلترینگ مشارکتی، در دو مرحله یادگیری و آزمایش اجرا شد. در مرحله یادگیری، الگوریتم با استفاده از داده‌های سال‌های ۱۳۹۱ تا ۱۳۹۵ آموزش داده شد و در مرحله آزمایش، عملکرد آن روی داده‌های سال‌های ۱۳۹۵ تا ۱۴۰۰ ارزیابی شد. در گام بعدی با استفاده از الگوریتم فیلترینگ مشارکتی مبتنی بر سهام، سیگنال خرید و فروش در طول دوره محاسبه و در نهایت، استراتژی ارزیابی شد.

**استناد:** نوراحمدی، مرضیه؛ رحیمی، علی و صادقی، حجت الله (۱۴۰۳). طراحی سیستم توصیه‌کننده سهام مبتنی بر الگوریتم فیلترینگ مشارکتی برای بورس اوراق بهادار تهران. *تحقیقات مالی*, ۲۶(۲)، ۳۱۸-۳۴۶.

**یافته‌ها:** الگوریتم به عنوان یک استراتژی سرمایه‌گذاری، در دو دوره درون‌نمونه‌ای و برون‌نمونه آزمایش شد. نتایج به دست آمده از طریق الگوریتم برای دوره‌های برون‌نمونه نشان می‌دهد که این استراتژی می‌تواند ۲۵ برابر بازدهی داشته باشد؛ در حالی که شاخص کل در این بازه زمانی ۱۶ برابر شده که نشان‌دهنده عملکرد عالی استراتژی در طول دوره زمانی است. همچنین میزان ارزش در معرض ریسک در دوره زمانی مورد بررسی، برای روش منتخب ۱۲/۸ درصد است که میزان ریسک کمتر این روش را نشان می‌دهد.

**نتیجه‌گیری:** الگوریتم فیلترینگ مشارکتی مبتنی بر سهام، نوعی استراتژی سرمایه‌گذاری فعال است. هدف این الگوریتم هوشمند، شناسایی سهام ارزشمند و کسب بازدهی بیشتر از بازار است و می‌تواند در این زمینه به سرمایه‌گذاران کمک کند. این الگوریتم می‌تواند ابزاری ارزشمند برای سرمایه‌گذاران فعالی باشد که به دنبال یافتن سهام ارزشمند و کسب بازدهی بیشتر از بازار هستند. بنابراین پژوهش‌های بیشتر برای بررسی عملکرد این الگوریتم در بازارهای مختلف و شرایط اقتصادی متنوع ضروری است. همچنین، به پژوهشگران بعدی توصیه می‌شود که از استراتژی‌های کنترل ریسک بهره ببرند و این عملکرد سیستم را تقویت کنند.

**کلیدواژه‌ها:** سیستم توصیه‌کننده، فلیترینگ مشارکتی، انتخاب سهام، اثر انتقال، پیش‌بینی سهام.

## مقدمه

امروزه، میزان اطلاعاتی که ما بازیابی و استفاده می‌کنیم، به سرعت افزایش یافته است. داده‌کاوی فرایند استخراج داده‌های مربوط از حجم زیادی از داده‌ها و همچنین روش کشف و پیدا کردن الگوی مناسب از حجم زیادی از مجموعه داده‌هاست. هدف اصلی از فرایند داده‌کاوی این است که اطلاعات مناسب و مرتبط از حجم زیادی از مجموعه داده‌ها استخراج و به ساختار فهم پذیر تبدیل شود. یکی از زیر مجموعه‌های داده‌کاوی، سیستم‌های توصیه‌کننده است (پاتل، دیسایی و پانچال<sup>۱</sup>، ۲۰۱۷). سیستم‌های توصیه‌کننده، در اواسط دهه ۱۹۹۰ ظاهر شدند؛ اما از زمان جایزه نتفلیکس<sup>۲</sup> توجه شایان توجهی را کسب کردند. امروزه، سیستم‌های توصیه‌کننده در مقیاس وسیعی از حوزه‌ها از قبیل فیلم‌ها (نتفلیکس)، کتاب (آمازون)<sup>۳</sup> یا موسیقی (اسپویتیفای)<sup>۴</sup> به کار گرفته می‌شوند. به طور کلی، از آنجایی که انتخاب‌های زیادی در سیستم وجود دارد و کاربران فقط به بخش کوچکی از آیتم‌ها علاقه دارند، سیستم‌های توصیه‌کننده در هر دامنه‌ای مفیدند (زیریکی<sup>۵</sup>، ۲۰۱۶). با توسعه این تکنیک‌های توصیه، سیستم‌های توصیه بیشتر و بیشتری اجرا شده است و بسیاری از برنامه‌های کاربردی سیستم‌های توصیه در دنیای واقعی ایجاد شده‌اند. کاربرد سیستم‌های توصیه عبارت‌اند از: توصیه اخبار، تور، مقاله‌ها، فیلم‌ها، موسیقی‌ها، کتاب‌ها، اسناد و زمینه‌های تجارت الکترونیک، آموزش الکترونیک، مدیریت الکترونیک و خدمات تجارت الکترونیک (پاتل و همکاران، ۲۰۱۷).

یکی از کاربردهای سیستم‌های توصیه‌کننده، در حوزه مالی است. شرکت‌های خدمات مالی از قبیل بانک‌ها، کارگزاری‌ها، اداره‌های خانوادگی، شرکت‌های بیمه زندگی و تراست‌ها، خدمات سرمایه‌گذاری را به مشتریان خود ارائه می‌دهند و به آن‌ها کمک می‌کنند تا به اهداف خود دست یابند. این گونه خدمات سرمایه‌گذاری، معمولاً شامل مشاوره در استراتژی‌های سرمایه‌گذاری، مدیریت پرتفولیو اختیاری که در آن مشتریان، مدیریت پرتفولیو را به خبرگان این حوزه از بازارهای مالی محول می‌کنند.

توصیه استراتژی‌های سرمایه‌گذاری مالی کار پیچیده‌ای است. به طور عمده، مشاوران مالی باید قبل از اینکه گزینه‌ای پیدا کنند که همه نیازها و محدودیت‌های سرمایه‌گذاران را برآورده کند با مشتریان ثروتمند خود گفت و گو کنند و از بین چندین پیشنهاد سرمایه‌گذاری، مناسب‌ترین آن را پیدا کنند.

در واقع، شناختن مشتریان و ارائه پیشنهادهای سرمایه‌گذاری شخصی به آن‌ها، امروزه یک جنبه ضروری از یک استراتژی مشورتی سودمند و مؤثر است. سرمایه‌گذاری‌های فناوری اطلاعات در جهت افزایش شفافیت، ارائه گزارش بهتر و به موقع به مشتری است؛ اما بر روند تصمیم‌گیری سرمایه‌گذاری تأثیر نگذاشته است.

بازار بورس حاوی اطلاعاتی است که با استفاده از درک آن اطلاعات، می‌توان سود کسب کرد. استراتژی‌های معاملاتی سعی می‌کنند که از این اطلاعات، برای بدست آوردن الگوهای موجود در داده‌های تاریخی و کسب سود

1. Patel, Desai & Panchal

2. Netflix

3. Amazon

4. Spotify

5. Zibriczky

استفاده کنند. سهام به عنوان یکی از مهم‌ترین ابزارهای مالی قابل معامله است و معمولاً سرمایه‌گذاران از آن استفاده می‌کنند و نشان‌دهنده مالکیت شرکت است. ارزش بازار یک شرکت برابر با قیمت سهام آن در تعداد سهام آن است و زمانی که ارزش یک شرکت یا انتظار ارزش شرکت در بازار تغییر می‌کند، قیمت سهام متناسب با آن تغییر می‌کند. سرمایه‌گذاران می‌توانند سهام را در بازارهای مالی بخرند یا بفروشند. با سرمایه‌گذاری در یک سهام، سرمایه‌گذاران انتظار دارند که یا سود نقدی از شرکت دریافت کنند یا از افزایش قیمت آن سهم در قیمتی بالاتر از قیمت خریداری شده سود کسب کنند. پیش‌بینی سهام مسئله‌ای است که هم سرمایه‌گذاران و تحلیلگران مالی به آن توجه می‌کنند و برای محققان دانشگاهی نیز جالب است. نظریه‌های پیش‌بینی را می‌توان به دو دسته تقسیم‌بندی کرد: نظریه ارزشیابی<sup>۱</sup> و نظریه کمی<sup>۲</sup>.

نظریه ارزشیابی بر ارزش خود شرکت تمرکز می‌کند. قیمت سهام نشان‌دهنده اطلاعات جامعی از گذشته، حال و آینده مورد انتظار شرکت در نظر گرفته می‌شود. اطلاعات گذشته و حال را می‌توان به طور دقیق محاسبه و در قیمت سهام منعکس کرد؛ در حالی که اطلاعات آینده ناشناخته است. بنابراین، سرمایه‌گذاران باید عملکرد آینده شرکت را پیش‌بینی کنند. یکی از روش‌های ارزش‌گذاری، تحلیل تنزیل جریان‌های نقدی (DCF)<sup>۳</sup> است. تحلیل تنزیل جریان‌های نقدی، یکی از روش‌های ارزش‌گذاری شرکت است که بر پایه جریان‌های نقدی آینده آن قرار دارد. کلیه جریان‌های نقدی آینده برآورد و به زمان حال تنزیل می‌شوند. اگر قیمت سهام محاسبه شده از طریق DCF با قیمت فعلی سهام مطابقت داشته باشد، بازار کارا تلقی شده و فرستی برای کسب سود مازاد وجود ندارد. اما گاهی قیمت سهام با قیمت تخمینی مطابقت ندارد و بدین معناست که سهام ممکن است کمتر یا بیشتر از حد تخمین زده شده باشد. یکی از مهم‌ترین دلایل برای این وضعیت در نظریه ارزشیابی، این است که قیمت سهام تحت تأثیر احساسات سرمایه‌گذاران، تأخیر تفسیر اطلاعات و سایر عوامل قرار دارد؛ اما قیمت بازار سهام همیشه حول قیمت واقعی حرکت می‌کند و بازار به تدریج تمام اطلاعات را منعکس می‌کند و قیمت به سمت قیمت واقعی خود بازمی‌گردد. نظریه کمی بیشتر از آنکه به ارزش شرکت تمرکز کند، روی حرکت قیمت سهام متمرکز است.

روش‌های کمی از شاخص‌های آماری زیادی مانند نوسان‌ها، متوسط قیمت، حجم، خط روند و سایر عوامل برای پیش‌بینی قیمت سهام استفاده می‌کنند. بر اساس مفروضات اساسی مختلف بازار، نظریه‌ها را می‌توان به دو دسته تقسیم کرد: تئوری‌های مختلف تکنیکال و تئوری گشت تصادفی.

نظریه‌های چارتیست یا تکنیکال، فرض می‌کنند که حرکت گذشته قیمت سهام حاوی اطلاعاتی در مورد حرکت آینده آن است، یعنی تاریخ تکرار می‌شود و در این الگوهای قیمت گذشته تمایل به تکرار در آینده دارند (چاوارناکول و انکه<sup>۴</sup>؛ ۲۰۰۸؛ چانگ و نگ<sup>۵</sup>؛ ۲۰۰۸؛ فرناندز رودریگار، ساویلا و آندرادا<sup>۶</sup>، ۱۹۹۹). تحلیلگر تکنیکال سعی می‌کند تا از

1. Valuation theory

2. Quantitative theory

3. Discounted cash flow

4. Chavarnakul & Enke

5. Chong & Ng

6. Fernandez Rodriguez, Sosvilla-Rivero & Andrada Félix

طریق شکل‌هایی که قیمت تاریخی بازار و اندیکاتورهای تکنیکال را نشان می‌دهند، بازار سهام را پیش‌بینی کند (سورشکومار و الانگو<sup>۱</sup>، ۲۰۱۱؛ وی، چن و هو<sup>۲</sup>، ۲۰۱۱؛ دی ایویرا، نوبر و زاراته<sup>۳</sup>، ۲۰۱۳؛ نتی و همکاران<sup>۴</sup>، ۲۰۱۵؛ سو و چنگ<sup>۵</sup>، ۲۰۱۶؛ دیکسون<sup>۶</sup>، ۲۰۱۵). در مقابل، تئوری گشت تصادفی می‌گوید که قیمت سهام طبق الگوهای مشخص حرکت نمی‌کند (فاما<sup>۷</sup>، ۱۹۹۵؛ وان هورن و پارکر<sup>۸</sup>، ۱۹۶۷) و این فرض را در نظر می‌گیرد که تغییرات روزانه قیمت سهام از هم مستقل هستند و قیمت‌ها با توجه به برخی از توزیع‌های احتمال حرکت می‌کنند. با توسعه آمار و علوم کامپیوترا، روش‌های کمی پیشرفته‌تر و پیچیده‌تری مانند آرج<sup>۹</sup> (بالداف و ساتانی<sup>۱۰</sup>، ۱۹۹۱؛ سانگ<sup>۱۱</sup>، ۱۹۹۴)، گارچ<sup>۱۲</sup> (جاندو و راکینگر<sup>۱۳</sup>، ۲۰۰۶؛ کارولی<sup>۱۴</sup>، ۱۹۹۵)، مدل گری<sup>۱۵</sup> (هسو، لیو، یه و هانگ<sup>۱۶</sup>، ۲۰۰۹؛ لی، یاماگوچی و ناگائی<sup>۱۷</sup>، ۲۰۰۸)، مدل شبکه‌های عصبی مصنوعی<sup>۱۸</sup> (کیموتو و همکاران<sup>۱۹</sup>، ۱۹۹۰؛ وايت<sup>۲۰</sup>، ۱۹۸۸) ارائه شد.

دولو و طبرسا (۱۳۹۹) در پژوهشی آزمون سودآوری سبکی از روش تحلیل پرتفوی برای استراتژی‌های دوره تشکیل و نگهداری ۳، ۶ و ۱۲ ماهه استفاده کردند. بر اساس نتایج به دست آمده، برای استراتژی‌های ۳ و ۶ ماهه، عدمه سود مومنتوم سبکی از طریق تئوری تداوم بازده توضیح داده می‌شود و برای استراتژی ۱۲ ماهه، ریسک، مؤلفه اصلی سودآوری مومنتوم سبکی محسوب می‌شود.

ولیدی و نجفی و ولیدی (۱۳۹۹) در پژوهش خود از اصل بازگشت به میانگین چند دوره‌ای که مبنای الگوریتم‌های تبعیت از بازنده است، استفاده کردند. آن‌ها نشان دادند که استفاده از بازگشت به میانگین چند دوره‌ای، بهتر می‌تواند مفهوم بازگشت به میانگین را منعکس کند. علاوه بر این، بهره‌مندی از خبرگان مختلف، دقت پیش‌بینی‌ها را افزایش داده و در نتیجه پرتفوهای بهتری پیشنهاد می‌شود. نوراحمدی و صادقی (۱۴۰۱) از تکنیک یادگیری ماشین برابری ریسک سلسله‌مراتبی (HRP) استفاده کردند و نشان دادند که رویکرد برابری ریسک سلسله‌مراتبی عملکرد بهتری نسبت به رویکرد مینیمم واریانس دارد.

1. Sureshkumar & Elango
2. Wei, Chen & Ho
3. De Oliveira, Nobre & Zarat
4. Nti et al.
5. Su & Cheng
6. Dickson
7. Fama
8. Van Horne & Parker
9. ARCH
10. Baldauf & Santoni
11. Song
12. GARCH
13. Jondeau & Rockinger
14. Karolyi
15. Grey Model
16. Hsu, Liu, Yeh & Hung
17. Li, Yamaguchi & Nagai
18. Artificial Neural Networks
19. Kimoto, Asakawa, Yoda & Takeoka
20. White

رویکرد ما در این پژوهش مبتنی بر تئوری کمی است. ثابت شده است که سهام مختلف با یکدیگر تعامل دارند. اوینگ<sup>۱</sup> (۲۰۰۲) از روش تجزیه واریانس خطای پیش‌بینی برای مطالعه تعامل بین پنج صنعت بزرگ در ایالات متحده استفاده می‌کند که نشان می‌دهد که سهام در صنایع مشابه همزمان بالا یا پایین می‌روند. اوینگ همچنین دریافت که صنایع مختلف بر یکدیگر تأثیر می‌گذارند، با بیشترین هماهنگی با صنایع همسایه که نشان‌دهنده اثر انتقال در صنایع متفاوت است (کوتناس و بوث<sup>۲</sup>؛ ۱۹۹۵؛ یین و دنگ<sup>۳</sup>؛ ۲۰۱۸؛ یین و همکاران<sup>۴</sup>؛ ۲۰۱۷).

اثر انتقال بین سهام<sup>۵</sup> را می‌توان تا حدی به دو روش توضیح داد. از نقطه نظر افقی، در یک نقطه از زمان، حرکت سهام در یک صنعت می‌تواند تحت تأثیر نظر سرمایه‌گذاران در آن صنعت قرار بگیرد (گائو و ساویکاس<sup>۶</sup>، ۲۰۰۶)، بنابراین کلیه سهام در صنعت به طور مشابه با یکدیگر حرکت خواهند کرد (باربر، اردن<sup>۷</sup>؛ شیلر<sup>۸</sup>؛ ۱۹۸۹). از نقطه نظر عمودی، تغییر در قیمت سهام در یک صنعت بر صنایع بالادستی و پایین دستی در امتداد زنجیره صنعتی تأثیر می‌گذارد (دی و لی<sup>۹</sup>؛ ۲۰۰۴؛ اسچمیتز و هامپری<sup>۱۰</sup>؛ ۲۰۰۰)؛ زیرا بهبود انتظارات از فعالیتهای یک صنعت، انتظارات بازار از صنایع مرتبط را بهبود می‌بخشد و این بهبود در افزایش قیمت سهام منعکس می‌شود.

توجه به اثر انتقال مهم است؛ اما کمی کردن آن دشوار است. به همین دلیل است که بسیاری از الگوریتم‌های کمی اثر انتقال بین سهام را در نظر نمی‌گیرند. در این پژوهش به پیش‌بینی سهام با ایجاد یک الگوریتم مبتنی بر فیلترینگ مشارکتی استفاده شده است. این روشی است که توسط سیستم‌های توصیه‌کننده برای کمی کردن و به کارگیری اثر انتقال در پیش‌بینی سهام استفاده می‌شود. هدف از این استراتژی پیدا کردن سهام خوب برای کسب بازده‌ای بیشتر از بازار است. در ادامه به پیشینه پژوهش‌های انجام شده در این حوزه پرداخته می‌شود.

## پیشینه پژوهش

سیستم‌های توصیه‌کننده (RS) ابزارها و تکنیک‌های نرم‌افزاری هستند که آیتم‌هایی را پیشنهاد می‌کنند که برای کاربر قابل استفاده است (ریسی و همکاران<sup>۱۱</sup>). سیستم‌های توصیه ابزارها و روش‌های نرم‌افزاری برای کشف پیشنهادها / توصیه‌هایی برای آیتم‌هایی هستند که برای کاربران مفید است. این پیشنهادها با فرایندهای تصمیم‌گیری مختلفی مرتبط هستند، مانند آیتم‌هایی که کاربران باید بخوند، فیلم‌هایی که تماشا می‌کنند، موسیقی‌هایی که گوش می‌دهند یا اخباری که می‌خوانند. بیشتر سیستم‌های توصیه برای برنامه‌های مختلف طراحی شده‌اند. هدف اصلی

1. Ewing
2. Koutmos & Booth
3. Yin & Deng
4. Yin et al.
5. transmission effect
6. Guo & Savickas
7. Barber & Odean
8. Shiller
9. Du & Li
10. Schmitz & Humphrey
11. Ricci et al

سیستم‌های توصیه این است که گزینه مناسبی را برای کاربران حقيقی ارائه دهدن. سیستم‌های توصیه این قابلیت را دارند که بر اساس تاریخچه و نمایه کاربران پیشنهاد کنند که آیا کاربر آیتم خاصی را ترجیح می‌دهد یا نه (پاتل و همکاران، ۲۰۱۷). سیستم‌های توصیه‌کننده سعی می‌کنند که ترجیحات کاربر را کشف کنند و در مورد آن‌ها اطلاعاتی می‌گیرند تا نیازهای آن‌ها را پیش‌بینی کنند. به طور گسترده، سیستم توصیه‌کننده پیشنهادهای خاصی راجع به آیتم‌ها (محصولات یا اقدامات) در یک حوزه ارائه می‌دهند که ممکن است مورد توجه کاربر قرار بگیرد (دی کامپوس<sup>۱</sup>، ۲۰۱۰).

سیستم‌های توصیه‌کننده به صورت کلی دو نتیجه دارند (نوراحمدی و صادقی، ۱۴۰۱):

۱. به کاربر در تصمیم‌گیری کمک می‌کنند (به طور مثال، از میان چندین گزینه پیش رو کدام انتخاب بهتر است و...).

۲. باعث افزایش آگاهی کاربر، در زمینه علاقه وی می‌شود (به طور مثال، در حین ارائه پیشنهاد، کاربر با اقلام و اشیاء جدیدی که قبل‌آن‌ها نمی‌شناخته است، آشنا می‌شود).

شایان ذکر است که آیتم یک عبارتی است برای مشخص کردن یا معنی چیزی که سیستم به کاربران برای استفاده توصیه می‌کند و کاربر کسی است که پیشنهاد را دریافت می‌کند و همچنین کسی که امتیازهای لازم برای تولید پیشنهادها را فراهم می‌کند.

تا کنون مطالعات بسیاری در این خصوص انجام شده است که در ادامه، به مهم‌ترین این پژوهش‌ها در حوزه بازار سهام اشاره می‌کنیم.

ویسمایا و همکاران<sup>۲</sup> (۲۰۱۹) در مطالعه خود تلاش کردند تا سیستم توصیه‌کننده معاملات سهام مبتنی بر طبقه‌بندی پیشنهاد کنند. آن‌ها از داده‌های تاریخی قیمت سهام و شاخص‌های تکنیکالی به عنوان ورودی‌ها استفاده کردند.

پتل<sup>۳</sup> (۲۰۱۹) با استفاده از یک مدل ترکیبی، به ارائه توصیه‌کننده سهام پرداخت. در این مدل، یک مدل توصیه سهام برای به دست آوردن سود، از طریق تحلیل شبکه‌های اجتماعی الکترونیک ارائه شده است.

دی راسی، کالودزیجی و برار<sup>۴</sup> (۲۰۱۹) در پژوهش خود به ارائه سیستم توصیه‌کننده فعالانه برای سهام پرداختند. هدف آن‌ها تجهیز مدیران پرتفلیو سهام به ابزاری جدید برای کمک به آن‌ها در وظیفه محدود کردن فهرست سهام بود تا بتوانند سهام را به طور دقیق تجزیه و تحلیل کنند.

پارانجape و دزپسند<sup>۵</sup> (۲۰۱۳) به ارائه سیستم توصیه‌کننده مبتنی بر قواعد انجمنی پرداختند. در این پژوهش یک سیستم توصیه‌کننده پرتفلیو بازار سهام را بر اساس قواعد انجمنی ارائه می‌کند که داده‌های سهام را تجزیه و تحلیل کرده و یک سبد رتبه‌بندی سهام را نشان می‌دهد.

1. De Campos

2. Vismayaa et al.

3. Patel

4. De Rossi, Kolodziej Brar

5. Paranjape-Voditel & Deshpande

آرامو، کاپلانسکی و لوی<sup>۱</sup> (۲۰۱۸) در پژوهش خود به بررسی توصیه سرمایه‌گذاری تکنیکال در مقابل بنیادی پرداختند. بگ و کالکارنی<sup>۲</sup> (۲۰۱۷) در مقاله خود بر پیش‌بینی روند قیمت سهام با استفاده از اخبار متنی آنلاین تأکید می‌کنند. ویژگی‌های متنی از طریق سایت‌های خبری استخراج شده و توصیه‌هایی بر اساس تفسیرها تولید می‌شود. موستو و همکاران<sup>۳</sup> (۲۰۱۵) در مقاله خود چارچوبی برای توصیه استراتژی‌های تخصیص دارایی پیشنهاد می‌کنند که استدلال مبنی بر مبانی را با استراتژی‌های جدید نوع بخشی، برای پشتیبانی مشاوران مالی در زمینه پیشنهاد پرتفلیوی متعدد و پرتفولیو سرمایه‌گذاری شخصی‌سازی شده ترکیب می‌کند. عملکرد چارچوب با استفاده از تجربیات ۱۱۷۲ کاربر واقعی ارزیابی شده است. نتایج نشان می‌دهد که بازده به دست آمده از پرتفلیو توصیه شده، بر پرتفلیو ارائه شده توسط مشاوران انسانی در بیشتر زمینه‌های آزمایشی غالب است؛ در حالی که ریسک ترجیحی پرتفلیو را هم رعایت می‌کند. زیربیکی (۲۰۱۶) در مقاله خود به مروری بر کاربردهای سیستم‌های توصیه‌کننده در حوزه‌های مختلف مالی می‌پردازد. هدف این مقاله توسعه این نوع سیستم‌ها در حوزه‌های مختلف است. یو و همکاران<sup>۴</sup> (۲۰۱۸) در مقاله خود یک مدل توصیه گروهی مبنی بر شبکه اجتماعی مالی و الگوریتم‌های فیلترینگ مشارکتی ارائه می‌کنند. در ادامه به بررسی روش فیلترینگ مشارکتی که مدل اصلی پژوهش است می‌پردازیم.

سیستم توصیه‌کننده فیلترینگ مشارکتی (CF) اساساً برای پیش‌بینی مطلوبیت آیتم‌هایی برای کاربران بر اساس آیتم‌هایی که قبلاً توسط سایر کاربران رتبه‌بندی شده‌اند، طراحی و استفاده می‌شوند. به طور رسمی‌تر، مطلوبیت ( $c, s$ ) آیتم  $s$  برای کاربر  $c$  بر اساس مطلوبیت‌های ( $c_j, s$ )  $u$  منصوب به آیتم  $s$  برای کاربرانی که  $c \in C_j$  که مشابه کاربر  $c$  هستند (آدامویشس و تازیلین<sup>۵</sup>، ۲۰۰۵). علاوه‌بر این، الگوریتم‌های توصیه‌هایی مشارکتی را می‌توان به دو کلاس کلی طبقه‌بندی کرد: مبنی بر مدل و مبنی بر حافظه (بریز، هکرمن و کادی<sup>۶</sup>، ۲۰۱۳).

تفاوت عمده بین مدل فیلترینگ مشارکتی مبنی بر مدل و مبنی بر حافظه‌ای است که فیلترینگ مشارکتی مبنی بر حافظه نیاز به آموزش هیچ مدل و مقیاسی ندارد و مدل فیلترینگ مشارکتی مبنی بر حافظه به طور کلی به مدل مبنی بر کاربر و مدل مبنی بر آیتم دسته‌بندی می‌شود. اصل الگوریتم مدل مشارکتی مبنی بر کاربر، جمع کردن تمام جفت‌های رفتاری ( $>$  user, item  $<$ ) و ایجاد توصیه است. برای مثال، بر اساس سوابق تاریخی همه کاربران، می‌توان دریافت که کاربران A و B بسیار مشابهند (ذائقه مشابهی دارند). در این حالت، اگر کاربر B آیتم c را ترجیح بدهد، گرچه ما چیزی در مورد کاربر A نمی‌دانیم، اما می‌توان آیتم c را به کاربر A توصیه کنیم. فیلترینگ مشارکتی مبنی بر کاربر بدلیل پراکندگی انتخاب مورد انتقاد قرار می‌گیرد؛ زیرا یک سیستم بزرگ توصیه‌گر معمولاً شامل آیتم‌های مختلفی است. کاربران ممکن است فقط بخش‌های خاصی از آیتم‌ها را انتخاب کنند (پاپاگلیس و همکاران<sup>۷</sup>، ۲۰۰۵). هم‌پوشانی

1. Avramov, Kaplanski & Levy

2. Bag & Kulkarni,

3. Musto, Semeraro, Lops, De Gemmis & Lekkas

4. Xue, Zhu, Liu, & Yin

5. Adomavicius & Tuzhilin

6. Breese, Heckerman & Kadie

7. Papagelis, Plexousakis & Kutsuras

انتخاب بین کاربران مختلف نسبتاً کم است که ذاتاً باعث می‌شود فیلترینگ مشارکتی مبتنی بر کاربر نتواند فهرستی از همسایگان قابل اعتماد را ایجاد کند (منظور کاربرانی است که ترجیحات مشابهی دارند). همچنین به دلیل پیچیدگی محاسباتی، الگوریتم مقصص شناخته شده است؛ زیرا پیچیدگی محاسباتی نزدیک‌ترین همسایگان با افزایش تعداد کاربران و آیتم‌ها، بسیار سریع رشد می‌کند. با این حال فیلترینگ مشارکتی مبتنی بر آیتم کاملاً متفاوت است. با مطالعه رفتار همه جفت‌ها ( $\langle user, item \rangle$ ، فیلترینگ مشارکتی مبتنی بر آیتم، آیتم  $a$  و  $b$  را که خیلی مشابهند، پیدا می‌کند (یعنی، آن‌ها توسط گروهی از افراد در یک زمان یکسان پذیرش شده است). سپس آیتم  $b$  را به کاربر A توصیه می‌کنیم. از آنجایی که شباهت آیتم نسبتاً ثابت است، می‌توان شباهت بین آیتم‌ها مختلف را به صورت آفلاین محاسبه کرد و شباهت را به صورت یک ماتریس بزرگ ذخیره کنیم. با توجه به سوابق تاریخی هر کاربر، می‌توانیم فهرستی از آیتم‌های مورد پذیرش کاربران در ماتریس را جستجو کرده و بر اساس شباهت آیتم‌ها، توصیه‌ای را ارائه دهیم. در این روش، توصیه مبتنی بر آیتم می‌تواند به طور همزمان پیچیدگی و پراکنده‌گی الگوریتم را بیان کند.

همان‌طور که می‌بینیم، هسته اصلی الگوریتم فیلترینگ مشارکتی مبتنی بر حافظه، شباهت ( $sim(c, \hat{c})$  بین جفت کاربر و آیتم‌ها را پیدا کند و بیشترین شباهت را با روش مبتنی بر همبستگی دارد. برای تعریف این رویکرد، فرض کنید  $\{s \in S | r_{x,s} \neq \emptyset, r_{y,s} \neq \emptyset\}$  مجموعه آیتم‌هایی باشد که توسط کاربر  $x$  و  $y$  با هم امتیاز داده شده‌اند. بر اساس رویکرد همبستگی، ضریب همبستگی پیرسون برای مشابهت به صورت زیر است (زنگ و همکاران<sup>۱</sup>):

$$sim(x, y) = \frac{\sum_{s \in S_{xy}} (r_{x,s} - \bar{r}_x)(r_{y,s} - \bar{r}_y)}{\sqrt{\sum_{s \in S_{xy}} (r_{x,s} - \bar{r}_x)^2} \sqrt{\sum_{s \in S_{xy}} (r_{y,s} - \bar{r}_y)^2}} \quad (1)$$

در همبستگی مبتنی بر کسینوس، هر دو کاربر  $x$  و  $y$  به صورت برداری در فضای  $m$  بعدی هستند که سپس، مشابهت بین دو بردار می‌تواند بوسیله کسینوس بین آن‌ها محاسبه شود:

$$sim(x, y) = \cos(\vec{x}, \vec{y}) = \frac{\vec{x} \cdot \vec{y}}{\|\vec{x}\| \cdot \|\vec{y}\|} = \frac{\sum_{s \in S_{xy}} r_{x,s} r_{y,s}}{\sqrt{\sum_{s \in S_{xy}} r_{x,s}^2} \sqrt{\sum_{s \in S_{xy}} r_{y,s}^2}} \quad (2)$$

آدامویشس و تازیلین (۲۰۰۵) فرمول الگوریتم‌های فیلترینگ مشارکتی مبتنی بر حافظه را توصیف می‌کنند که رتبه  $r_{c,s}$  برای کاربر  $c$  و آیتم  $s$  بر اساس مجموع رتبه‌های دیگر کاربرانی که مشابه کاربر  $s$  هستند، ارزیابی می‌کند:

$$r_{c,s} = aggrr_{c,s}, c \in \hat{C} \quad (3)$$

که  $\hat{C}$  مجموعه N کاربری است که بیشترین شباهت را با کاربر C دارند و رتبه  $s$  دارند (N می‌تواند از ۱ تا تا تعداد کل کاربران باشد). بعضی از توابع مجموع به صورت زیر است:

$$r_{c,s} = \frac{1}{N} \sum r_{c,s}, c \in \hat{C} \quad (4)$$

1. Zheng, Gao, Yin & Rabarison

$$r_{c,s} = k \sum_{\hat{c} \in \hat{C}} \text{sim}(c, \hat{c}) \times r_{f,s}, \hat{c} \in \hat{C} \quad (\text{رابطه } ۵)$$

$$r_{c,s} = \bar{r}_c + k \sum_{\hat{c} \in \hat{C}} \text{sim}(c, \hat{c}) \times (r_{f,s} - \bar{r}_{\hat{c}}), \hat{c} \in \hat{C} \quad (\text{رابطه } ۶)$$

که  $k$  به صورت عامل نرمالایز و به صورت زیر محاسبه می‌شود:

$$k = \frac{1}{\sum_{\hat{c} \in \hat{C}} |\text{sim}(\hat{c} \in \hat{C})|} \quad (\text{رابطه } ۷)$$

و میانگین رتبه‌های کاربر  $C$  و  $\bar{r}_c$  به صورت زیر تعریف می‌شود:

$$\bar{r}_c = \left( \frac{1}{|S_c|} \right) \sum_{s \in S_c} r_{c,s}, \text{ where } S_c = \{s \in S | r_{c,s} \neq \emptyset\} \quad (\text{رابطه } ۸)$$

یک سیستم توصیه فیلترینگ مشارکتی شامل سه بخش است: ماثول ثبت مدل، ماثول تحلیل مدل و ماثول الگوریتم توصیه.

### اطلاعات حاصل از تحرکات سهم

در این پژوهش اعتقاد داریم که حرکت سهام دارای نوعی از اطلاعات است و حرکت یک سهم می‌تواند بر حرکت سهام دیگر تأثیر بگذارد. این فرضیه بر اساس نظریه ابتکاری نمایندگی<sup>۱</sup> است. نظریه ابتکاری نمایندگی در هنگام تصمیم‌گیری در شرایط عدم اطمینان استفاده می‌شود. نمایندگی در اینجا به معنی شباهت با جمعیت است. برای مثال، در ده ماه گذشته، وقتی سهام A افزایش یافته، سهام B نیز افزایش یافته است. اگر فرض کنید که قیمت سهام A افزایش یافته است، وقتی مردم این وضعیت را ملاحظه می‌کنند، مردم تمایل دارند که سهام B را نیز بخرند؛ زیرا تجربه به سرمایه‌گذاران می‌گوید که سهام B نیز قیمت‌ش افزایش خواهد یافت. برای مثال، به نظر می‌رسد افزایش سهام A خبری خوبی برای سهام B باشد. اگر چه ممکن است این دو سهام با یکدیگر ارتباط نداشته باشند، اما تجربه‌ای که سهام B از سهام A تبعیت کرده، باعث می‌شود که سرمایه‌گذاران تصور کنند که افزایش قیمت سهام A خبر خوبی برای سهام B است. در نظریه‌های تکنیکالی، سرمایه‌گذاران سعی می‌کنند بر ارتباط هم‌بستگی بین حرکت روزانه سهام تمرکز کنند. آن‌ها فرض می‌کنند که یک سهام به طور خاص پس از نوعی از حرکت، حرکت می‌کند.

در این پژوهش این مدل براساس فرض وجود هم‌بستگی بین سهام مختلف توسعه یافته است. صعود و سقوط گذشته سهام مرتبط با یک سهام را می‌توان برای پیش‌بینی حرکت سهام استفاده کرد.

در این قسمت به مقایسه فیلترینگ مبتنی بر سهام و فیلترینگ مبتنی بر حافظه سنتی می‌پردازیم (زنگ و همکاران<sup>۲</sup>). (۲۰۱۹).

1. Representativeness heuristic  
2. Zheng et al.

### جدول ۱. مقایسه بین فیلترینگ مبتنی بر سهام و فیلترینگ مبتنی بر حافظه

فیلترینگ مبتنی بر حافظه	فیلترینگ مبتنی بر سهام	
ترجیحات خرید مصرف کننده	ترجیحات معاملاتی کاربر	هدف <sup>۱</sup>
کالاهای را با توجه به ترجیحات مصرف کنندگان توصیه می‌کند.	بر اساس ترجیحات کاربر، سهامی که ممکن است توسط سرمایه‌گذار در دوره زمانی پیش‌بینی انتخاب شود پیدا می‌شود.	مقصود <sup>۲</sup>
رتیبه‌بندی مصرف کننده، خرید، دانلود، بروزرسانی و سایر داده‌های تاریخی	روندهای افزایشی و کاهشی سهام در دوره زمانی	ماژول ثبت رفتار
امتیاز کاربر و دیگر داده‌ها استاندارد شده و مدلی برای توصیف ترجیحات کاربر با توجه به نوع داده ساخته می‌شود.	استفاده از حرکات سهام انفرادی در دوره زمانی	ماژول تحلیل رفتار
محاسبه مشابهت بین کاربران	محاسبه اثر انتقال بین قبل و بعد سهام مختلف	توصیه
نزدیک‌ترین کاربر همسایه کاربر با توجه به ضربیه هم‌بستگی بین رتبه‌های کاربر به دست می‌آید. ماتریس رتبه‌بندی برای نزدیک‌ترین همسایگان کالاهای خاص محاسبه کنید. اولویت کاربر هدف را برای آیتم پیش‌بینی کنید و تعیین کنید که به او توصیه کنید یا نه؟!	گروهی از سهام شرکت‌های سهامی هدف با توجه به ضربیه تأثیر انتقال شوک مومتومن سهام انتخاب می‌شود. روندهای افزایشی و کاهشی گروه شرکت‌های مرتبط برای سهام خاص را دریافت کنید. ترجیحات سرمایه‌گذاران را برای سهام مورد نظر پیش‌بینی کرده و تعیین کنید که آیا آن را توصیه می‌کنید یا نه؟!	ماژول الگوریتم

منبع: (زنگ و همکاران، ۲۰۱۹)

### فرضیه‌ها یا سؤال‌های پژوهش

در این پژوهش از روش فیلترینگ مشارکتی استفاده می‌کنیم. مفروضات اصلی مدل فیلترینگ مشارکتی در قیمت سهام عبارت است از: ۱. بازار به اندازه کافی کارا نیست؛ ۲. حرکت سهام به خودی خود حاوی نوعی اطلاعات است که می‌تواند به ما در جهت شناسایی سهام کمک کند. سؤال اصلی این پژوهش این است که آیا روش فیلترینگ مشارکتی اثربخشی کافی در ارائه توصیه سهام دارد؟ به منظور پاسخ به سؤال پژوهش بازدهی استراتژی فیلترینگ مشارکتی با بازدهی شاخص کل و دو صندوق سهامی مقایسه می‌شود.

### روش‌شناسی پژوهش

داده‌های این پژوهش کلیه شرکت برتر بورس اوراق بهادار هستند. اولین مرحله از فرایند آماده‌سازی داده‌ها استخراج داده است؛ از این رو داده‌های روزانه تعديل شده کلیه شرکت‌های بورسی، برای دوره زمانی ۱۳۹۱/۰۱/۰۴ تا ۱۴۰۰/۰۴/۱۹<sup>۳</sup>

1. Object  
2. Purpose

(حدود ۵۹۹ سهم) برای ۲۱۸۲ روز معاملاتی، از طریق نرم‌افزار رهآورده استخراج شد. دومین مرحله از فرایند آماده‌سازی داده‌ها، پیش‌پردازش داده‌ها است. در ابتدای این مرحله لازم است داده‌ها از عواملی همچون نویز، داده‌های پرت و داده‌های گمشده که کیفیت داده‌ها را به مخاطره می‌اندازند، پاک‌سازی شوند. در این پژوهش ابتدا تعداد روز معاملاتی همه سهام بررسی شدند و با توجه به تعداد روزهای معاملاتی ۱۴۵ سهم باقی مانده و بقیه شرکت‌ها به دلیل عدم وجود اطلاعات معاملاتی کافی از جامعه آماری حذف شدند.

در این پژوهش قیمت پایانی تعیین شده به عنوان متغیر اصلی استفاده شده است. شروع آن با سری قیمت‌های خام  $P_{it}$  است که نشان از قیمت سهام شرکت ۱ در روز  $t$  است، همچنین  $P_{it-1}$  نشان دهنده قیمت سهام شرکت ۱ در روز  $t - 1$  است. با توجه به این که توزیع قیمت سهام به توزیع لاگ‌نرمال<sup>۱</sup> نزدیک است، برای محاسبه بازده داده‌ها از فرمول بازده لگاریتمی به صورت زیر استفاده می‌کنیم:

$$R_{it} = \ln \frac{P_{it}}{P_{it-1}} \quad \text{رابطه (۹)}$$

برای دو دارایی  $i$  و  $j$  ماتریس همبستگی به ماتریس همبستگی - فاصله  $D$  به شکل زیر تبدیل می‌شود:

$$D(X_i, X_j) = \sqrt{\frac{1}{2}(1 - \rho_{i,j})} \quad \text{رابطه (۱۰)}$$

## مراحل پیاده سازی روش فیلترینگ مشارکتی

### مرحله اول محاسبه ضریب اثر انتقال

مجموعه  $S_i$  را به عنوان مجموعه هدف در نظر بگیرید،  $C_{S_i} = \{S_1, S_2, \dots, S_{i-1}, S_{i+1}, \dots, S_n\}$  مجموعه همه سهامی است که در نمونه ما نسبت به سهام هدف قرار دارد. مطالعات از تحلیل Hurst-exponent-based زمانی مالی که دارای خصوصیات multi-scaling است، استفاده می‌کنند. طول دوره زمانی کوتاه و بلند توسط پس آزمایی انجام می‌شود. دوره کوتاه‌مدت و بلندمدت شامل روزهای معاملاتی است. تحرکات نسبی سهام هدف در دوره زمانی کوتاه به عنوان خصوصیات ارزش سهام در دوره زمانی کوتاه در نظر گرفته می‌شود.

دوره زمانی بلندمدت شامل مجموعه‌ای از دوره زمانی کوتاه‌مدت است ( $m \geq 2$ ). بردار high-dimensional  $X_{S_i, T_k}$  را با دوره زمانی بلندمدت خصوصیات  $[X_{S_i, T_{k,1}}, X_{S_i, T_{k,2}}, X_{S_i, T_{k,3}}, \dots, X_{S_i, T_{k,m}}]$  به عنوان  $m$  نماینده را با دوره زمانی بلندمدت خصوصیات  $X_{S_i, T_{k,t}}$  نشان دهنده درصد سهام  $S_i$  است که سهام هدف  $S_i$  در  $k^{th}$  امین دوره زمانی بلندمدت  $T_k$  در نظر می‌گیریم که در دوره زمانی کوتاه‌مدت  $t$  افزایش یا کاهش داشته است (زنگ و همکاران، ۲۰۱۹).

$$X_{S_i, T_{k,t}} = \frac{P_{S_i, T_{k,t, ending}} - P_{S_i, T_{k,t, beginning}}}{P_{S_i, T_{k,t, beginning}}} \quad \text{رابطه (۱۱)}$$

1. Lognormal

که  $P_{S_i, T_{k,t}, ending}$  نشان‌دهنده قیمت سهام  $S_i$  در آخرین روز معاملاتی دوره زمانی کوتاهمدت  $t$  در دوره زمانی بلندمدت  $T_k$  است و  $P_{S_i, T_{k,t}, beginning}$  نشان‌دهنده قیمت سهام  $S_i$  در اولین روز معاملاتی دوره زمانی کوتاهمدت  $t$  در دوره بلندمدت  $T_k$  است. سپس، ضریب همبستگی پیرسون بین بردار current high-dimensional سهام هدف و بردار دوره زمانی بلندمدت  $T_k$  همه سهام در  $C_{S_i} = [X_{S_i, T_{k-1,1}}, X_{S_i, T_{k-1,2}}, \dots, X_{S_i, T_{k-1,14}}]$  محاسبه می‌کنیم.

ضریب اثر انتقال  $T_{X_{S_i, T_{k,t}}, X_{S_j, T_{k-1,t}}}$  بین سهام  $S_i$  و مابقی سهام در نمونه را مشابه ضریب همبستگی پیرسون بین دو بردار به صورت زیر محاسبه می‌شود (زنگ و همکاران، ۲۰۱۹).

$$\begin{aligned} T_{X_{S_i, T_k}, X_{S_j, T_{k-1}}} &= P_{X_{S_i, T_k}, X_{S_j, T_{k-1}}} = \frac{\text{cov}(X_{S_i, T_k}, X_{S_j, T_{k-1}})}{\sigma_{X_{S_i, T_k}} \sigma_{X_{S_j, T_{k-1}}}} \\ &= \frac{E(X_{S_i, T_k} - \mu_{S_i, T_k})(X_{S_j, T_{k-1}} - \mu_{S_j, T_{k-1}})}{\sigma_{X_{S_i, T_k}} \sigma_{X_{S_j, T_{k-1}}}} \end{aligned} \quad (12)$$

که  $\text{cov}(X_{S_i, T_k}, X_{S_j, T_{k-1}})$  کواریانس است و  $\sigma_{X_{S_i, T_k}}$  واریانس استاندارد بین دو بردار است. زمانی که روابط خطی بین دو بردار افزایش یابد این ضریب اثر انتقال به یک نزدیک می‌شود (دقیقاً مشابه یکدیگرند) یا منفی یک (دقیقاً مخالف یکدیگرند).

### مرحله دوم: ساخت گروهی از شرکت‌های مرتبط

همان طور که در مرحله اول بیان شد، مدل ضریب اثر انتقال بین هر سهم (هدف) و مابقی سهام در نمونه را در دوره زمانی بلندمدت  $T_k$  محاسبه می‌کند. در مرحله دوم، ۵ سهام از  $C_{S_i}$  را برای محاسبه سهام هدف  $S_i$  به صورت زیر محاسبه می‌کند:

$$C_{S_i, T_k}^{positive} = \{S_{1st}^{positive}, S_{2nd}^{positive}, S_{3rd}^{positive}, S_{4th}^{positive}, S_{5th}^{positive}\} \quad (13)$$

در معادله بالا  $C_{S_i, T_k}^{positive}$  شامل ۵ سهم با  $T_{X_{S_i, T_k}, X_{S_j, T_{k-1}}}$  بزرگتر است، که بیشترین ارتباط مثبت را در سهام هدف دارد. این ۵ سهام مرتبط با گروههای سهام شرکت هدف است. برای هر دوره زمانی کوتاهمدت  $X_i$ ، مدل مجدد ضریب اثر انتقال را محاسبه کرده و گروه شرکت‌های جدید را برای هر سهم ایجاد می‌کند (زنگ و همکاران، ۲۰۱۹).

### مرحله سوم: محاسبه شاخص رتبه

مدل از قیمت ۵ سهام در سهام هدف مرتبط با گروههای شرکت در طول دوره زمانی استفاده می‌کند. ما شاخص رتبه را برای هر سهام هدف در طول دوره زمانی  $t$  به صورت زیر محاسبه می‌کنیم (زنگ و همکاران، ۲۰۱۹):

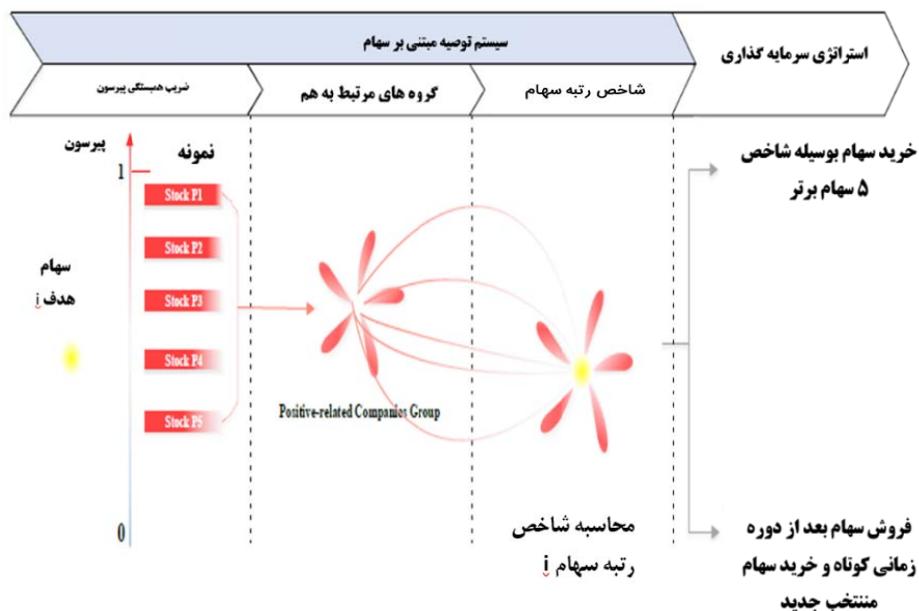
$$R_{i,t} = \sum_j^5 X_{S_j, t}^{positive} \quad (14)$$

در معادله ۱۲، هر  $s_j$  نماینده یک سهام در مجموعه گروهی از سهام  $s_i$  است.  $X_{Sj,t}^{positive}$  افزایش یا کاهش هر سهم  $s_j$  در آخرین دوره زمانی کوتاه‌مدت است همان‌طور که در رابطه ۱۱ محاسبه شد.

این شاخص به عنوان معیاری برای قدرت تحرک نسبی سهم در طول دوره کوتاه‌مدت بعدی است. انتظار می‌رود سهم با بالاترین شاخص رتبه افزایش قیمت بیشتری نسبت به سهام با شاخص رتبه پایین داشته باشد.

### استراتژی سرمایه‌گذاری

برای آزمون سودآوری مدل، یک استراتژی سرمایه‌گذاری بر اساس مدل مبتنی بر فیلترینگ مشارکتی مبتنی بر سهام ایجاد می‌کنیم. این استراتژی شامل استفاده از کلیه سرمایه‌های سرمایه‌گذاری برای خرید ۵ سهم با بالاترین رتبه  $R_{i,t}$  در ابتدای دوره، و فروش کلیه سهام موجود در آن و خرید ۵ سهم جدید در ابتدای دوره کوتاه‌مدت بعدی است. استراتژی سرمایه‌گذاری به صورت زیر است:



شکل ۱. استراتژی سرمایه‌گذاری مبتنی بر سهام

منبع: (زنگ و همکاران، ۲۰۱۹)

### یافته‌های پژوهش


#### دوره بهینه‌سازی

برای یافتن بهترین دوره کوتاه‌مدت و بلندمدت، داده‌های بازار سهام به دو قسمت تقسیم می‌شوند. یک قسمت به عنوان درون نمونه و یک قسمت به عنوان برون نمونه (آزمون).

نحوه انتخاب دوره زمانی و تفکیک دوره به درون نمونه و بروون نمونه به صورتی بوده است که در هر دو دوره هر دو نوع رژیم صعودی و نزولی بازار (ریزش سال ۹۶ و ریزش سال ۹۹) در داده‌ها باشد و داده‌ها تحت تأثیر یک رژیم خاص بازار قرار نگیرند.


از داده‌های سال‌های ۱۳۹۱/۰۱/۰۴ تا ۱۳۹۵/۰۶/۲۰ برای داده‌های درون نمونه (یادگیری) (۱۴۵ سهم و ۱۰۲۳ روز معاملاتی) و از داده‌های سال‌های ۱۳۹۵/۰۶/۲۱ تا ۱۴۰۰/۰۴/۱۹ برای داده‌ای بروون نمونه ( تست) (۱۴۵ سهم و ۱۱۵۹ روز معاملاتی) استفاده می‌کنیم.

محدوده آزمایش برای دوره کوتاه‌مدت از ۵ تا ۴۵ روز معاملاتی، و محدوده آزمایش برای دوره بلندمدت از ۲ تا ۱۰ برابر دوره کوتاه‌مدت است. ترکیب یک دوره کوتاه و یک دوره بلندمدت، که حداکثر ارزش خالص را به دست می‌آورد، به عنوان ترکیب بهینه‌سازی در نظر گرفته می‌شود. نتیجه در شکل ۲ نشان داده شده است. در شکل ۲، هرچه مربع‌ها سبزتر باشند، این ترکیب استراتژی سودآورتر است.



شکل ۲. ترکیب دوره زمانی کوتاه‌مدت و بلندمدت و میزان سود به دست‌آمده از استراتژی  
مأخذ: یافته‌های پژوهش

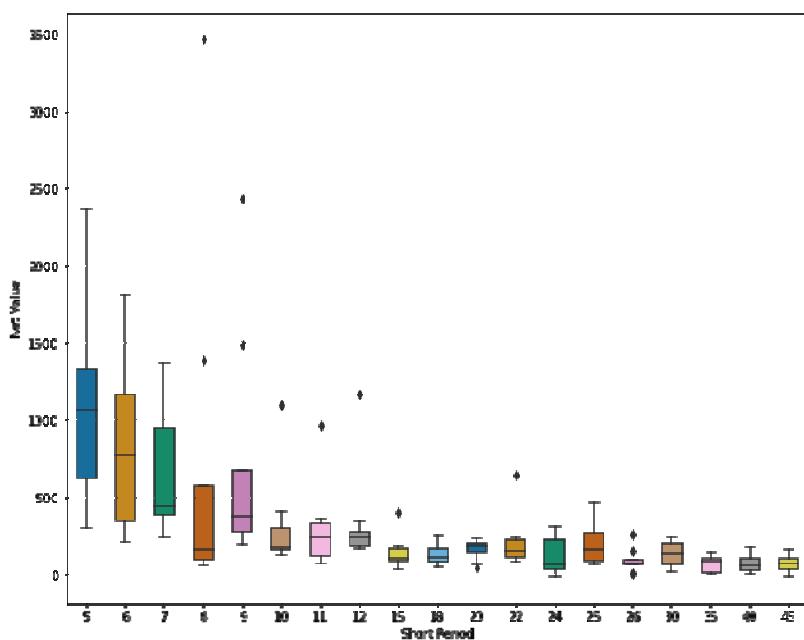
در شکل ۳ شکل جعبه‌ای برای دوره زمانی بلندمدت مشاهده می‌شود. با توجه به شکل می‌توان دریافت که هر چه قدر دوره زمانی بلندمدت بزرگ‌تر شود، وابستگی نتایج به دوره زمانی کوتاه‌مدت کمتر می‌شود.



شکل ۳. ارزش خالص در طی دوره‌های بلندمدت مختلف

مأخذ: یافته‌های پژوهش

از شکل دوره زمانی کوتاه‌مدت هم همان نتیجه گرفته می‌شود، ضمن اینکه برای دوره زمانی کوتاه‌مدت ۸ تا ۱۵ و ۲۲ داده پرتو داریم که نشان می‌دهد ممکن است به صورت تصادفی بازدهی‌های خیلی خوبی به دست آورده باشیم، حال آنکه این بازدهی‌ها در بلندمدت پایدار نخواهند بود.



شکل ۴. ارزش خالص در طی دوره‌های کوتاه‌مدت مختلف

مأخذ: یافته‌های پژوهش

شکل ۴ نیز نشان می‌دهد که با افزایش طول دوره کوتاه‌مدت، بازده استراتژیک به تدریج افزایش یافته و ثابت شود. با توجه به نتیجه آزمایش، بهترین طول دوره کوتاه ۹ روز است و بهترین دوره بلندمدت شامل ۳ برابر دوره کوتاه‌مدت است. این ترکیب در آزمایش مجدد اعمال می‌شود.


با توجه به نتایج شکل‌های باکس پلات و نقشه حرارتی دوره زمانی کوتاه‌مدت باید دوره زمانی‌ای برای آزمون انتخاب کنیم که حساسیت کمتری داشته باشد. بین ۴ انتخاب بهینه که در جدول ۲ گزارش شده است، دوره زمانی کوتاه‌مدت ۹ روزه و بلندمدت ۳ برای پس آزمایی انتخاب می‌شود. نتایج سودآوری برای درون‌نمونه و بروون‌نمونه در جدول ۲ گزارش شده است.

جدول ۲. نتیجه دوره زمانی بهینه در درون‌نمونه و بروون‌نمونه

کوتاه‌مدت	بلندمدت	دروون‌نمونه	بروون‌نمونه
۵	۹	۹	۸
۲	۲	۳	۳
۲۳۶۵/۵۴۶۱	۲۴۳۱/۱۴۶	۱۴۸۵/۸۵۷	۳۴۶۶/۹۹۶۳
۱۶۶۹/۲۷۵۳	۱۹۴۸/۲۲۴۱	۲۵۲۹/۲۶۵	۱۳۹۱/۴۳۸

منبع: یافته‌های پژوهش

در شکل ۵، نتیجه بازدهی برای بروون‌نمونه برای دوره کوتاه‌مدت ۳ و بلندت ۹ نمایش داده شده است. بازدهی این استراتژی ۲۵/۲۹ است که نسبت به بازدهی شاخص کل که در طول دوره بروون‌نمونه ۱۶ برابر شده، بهتر است.




شکل ۵. دوره کوتاه‌مدت ۳ و بلندمدت ۹، بروون‌نمونه ۲۵۲۹.۲۶۵

شاخص کل: ۱۶۰۰ برابر

مأخذ: یافته‌های پژوهش


در شکل ۶ هستوگرام بازدهی نمایش داده شده است. همان‌گونه که مشاهده می‌شود، این استراتژی در دوره‌های ریزش بازار نمی‌تواند به خوبی عمل کند، و این استراتژی نیاز به یک حد ضرر برای پوشش ریسک است.



شکل ۶. هیستوگرام توزیع فراوانی بازده


منبع: یافته‌های پژوهش

بنابراین برای اینکه زیان‌های این استراتژی را بتوانیم به نحوی کنترل کنیم، یک حد ضرر برای این استراتژی تعیین می‌کنیم که اگر میزان زیان از ۱۰ درصد بیشتر شد، از آن موقعیت خارج شود. با در نظر گرفتن این حد ضرر و ضعیت هیستوگرام بازدهی استراتژی به صورت زیر می‌شود و بازدهی از ۲۵/۲۹ به ۲۶/۲۹ می‌رسد که در شکل ۷ نشان داده شده است.



شکل ۷. تعیین حد ضرر ۱۰- درصد

مأخذ: یافته‌های پژوهش



شکل ۸. بازدهی استراتژی با در نظر گرفتن حد ضرر ۲۶۵۴ / ۲۶۲۹

مأخذ: یافته‌های پژوهش

### پس آزمایی

زمانی که یک مدل ریسک ساخته می‌شود، این موضوع برای ما اهمیت دارد که قبل از اینکه به صورت عملی مورد استفاده قرار دهیم، به دقت از نظر اعتبار سنجیده شود، و عملکرد آن بدقت بعد از آن به طور منظم ارزیابی شود. مدل‌های ریسک نیازمند این هستند که به طور منظم اعتبارشان سنجیده شوند و یکی از قابلیت‌های کلیدی سنجش اعتبار مدل پس آزمایی<sup>۱</sup> است. پس آزمایی استفاده از یک روش کمی برای بررسی سازگاری پیش‌بینی‌های مدل پیش‌بینی با مفروضات پایه‌ای مدل و یا رتبه‌بندی گروهی از مدل‌ها در مقایسه با یکدیگر است (داو، ۲۰۰۷). برای ارزیابی اعتبار الگوریتم، ما استراتژی سرمایه‌گذاری را روی دیتای واقعی پیاده می‌کنیم. معیارهای اصلی به شرح جدول ۳ است:

جدول ۳. معیارهای ارزیابی

ردیف	عنوان	رابطه
۱	ماکسیمم ریزش	$Max\ drawdown = \frac{\max(P_x - P_y)}{P_x}$
۲	نسبت شارپ	$Sharp\ Ratio = \frac{R_p - R_f}{\sigma_p}$
۳	نسبت سورتینو	$Sotino\ Ratio = \frac{R_p - R_f}{\sigma_{Pd}}$ $\sigma_{Pd} = Downside\ risk = \sqrt{\frac{250}{n} \sum_{i=1}^n (r_p - \bar{r}_{Pi})^2 f(t)}$ $\bar{r}_{Pi} = \frac{1}{i} \sum_{j=1}^i r_j$ $f(t) = 1 \text{ if } r_p < \bar{r}_{Pi}, \text{ if } r_p \geq \bar{r}_{Pi}$
۴	بازده کل	$= \frac{P_{end} - P_{start}}{P_{start}} * 100$
۵	بازده سالانه	$R_p = \left( (1 + P)^{\frac{250}{n}} - 1 \right) * 100$
۶	نوسانهای سالانه	$\sigma_p = \sqrt{\frac{250}{n} \sum_{i=1}^n (r_p - \bar{r}_p)^2}$

منبع: (زنگ و همکاران، ۲۰۱۹)

نسبت شارپ یا نسبت پاداش به نوسانات یکی از شناخته شده‌ترین روش‌ها برای ارزیابی عملکرد پرتفوی است. این نسبت در سال ۱۹۶۶ توسط ویلیام شارپ برای انجام تجزیه و تحلیل عملکرد مدیران صندوق‌های سرمایه‌گذاری مشترک توسعه پیدا کرد. این نسبت به سرمایه‌گذاران کمک می‌کند تا درک کنند که سرمایه‌گذاری‌هایشان تا چه اندازه برای ریسکی که پذیرفته‌اند جبران می‌شود.

یکی دیگر از معیارهای ارزیابی عملکرد هنگام بررسی پایداری پرتفلیو، نسبت سورتینو است که توسط سورتینو و پرایس در سال ۱۹۹۴ توسعه یافته است. این شاخص برخلاف نسبت شارپ، فقط انحرافات نزولی از میانگین را به عنوان

معیاری برای اندازه گیری ریسک در نظر می‌گیرد، بنابراین محدودیت‌های ارائه شده توسط انحراف معیار را که با انحرافات منفی و مثبت از میانگین یکسان برخورد می‌کند را اصلاح می‌کند.

ماکسیمم ریزش (MDD) معیار اندازه ریسک پرتفلیو است که حداکثر روند منفی بازده سهام را در طی یک دوره زمانی مشخص در نظر می‌گیرد. در واقع، این همان مقداری است که شکل از نقطه اوج به پایین‌ترین سطح خود رسیده است. حداکثر ریزش به سرمایه‌گذاران می‌گوید که در بدترین سناریو خرر در پرتفوی چقدر بزرگ است. با این وجود، این معیار هیچ اطلاعاتی در مورد تعداد دفعات ضرر و زمان سرمایه‌گذاران برای بازیابی از آن‌ها ارائه نمی‌دهد. ارزش در معرض ریسک، حداکثر زیان مورد انتظار بر پرتفوی سرمایه‌گذاری در مدت زمان معین و با فاصله اطمینان معین را نشان می‌دهد در حالی که ریزش مورد انتظار میان زیان به شرطی است که زیان فراتر از VaR رفته باشد (سارنج و نوراحمدی، ۱۳۹۵).

نتایج پس آزمایی برای استراتژی و مقایسه آن با شاخص کل و صندوق مبتنی بر سهام غیرقابل معامله در بورس به شرح جدول زیر است:

به‌طور کلی استراتژی CF با دوره زمانی کوتاه‌مدت ۹ و بلندمدت ۳، در طول دوره زمانی ۲۰۱۹ و ۲۰۲۰ و همچنین کل دوره زمانی ۲۰۱۶ تا ۲۰۲۱ عملکرد بهتری نسبت به شاخص کل و دو صندوق مبتنی بر سهام داشته است. اگرچه زمان بندی بازار در الگوریتم وجود ندارد، اما بازدهی از استراتژی بسیار قابل توجه است؛ به این معنی که مدل دارای قابلیت غربالگری سهام عالی است. در کل دروغ زمانی الگوریتم ۲۵ برابر شده، حال آنکه شاخص کل ۱۶/۵ برابر و دو صندوق مبتنی بر سهام نیز، به ترتیب ۱۷ و ۱۶ برابر شده‌اند. به‌طور کلی، نتایج پژوهش ما تأیید می‌کند که به کارگیری سیستم توصیه فیلترینگ مشارکتی در زمینه پیش‌بینی سهام و ارائه توصیه مبتنی بر آن امکان پذیر است.

جدول ۷. مقایسه الگوریتم پژوهش با شاخص کل و دو صندوق مبتنی بر سهام

ماکسیمم ریزش مورد انتظار	بازدهی					مدل
	۹۵/۰۶/۲۱ ۴۰۰/۰۴/۱۹	۹۸/۱۰/۱۱ ۹۹/۱۰/۱۰	۹۷/۱۰/۱۱ ۹۸/۱۰/۱۰	۹۶/۱۰/۱۱ ۹۷/۱۰/۱۰	۹۵/۱۰/۱۲ ۹۶/۱۰/۱۰	
-۰/۲۵۳	۲۵۲۹/۲۶۵	۵۶۰/۴۰۲	۳۱۱/۶۵	۸/۰۰۶	۱۳/۲۰۴	روش فیلترینگ مبتنی بر سهام کوتاه‌مدت ۹ و بلندمدت ۳
-۰/۳۸۹۶	۱۳۹۱/۴۳۸	۷۱۱/۳۰۲	۱۷۴/۶۸	۱۶/۳۴۵	-۱۲/۷۲	روش فیلترینگ مبتنی بر سهام کوتاه‌مدت ۸ و بلندمدت ۳
-۰/۴۵۷	۱۶۶۹/۲۷۵	۱۰۰۲/۹۲۹	۱۳۱/۰۵۶	۳۰/۶۴۴۳	۷/۶۴۵	روش فیلترینگ مبتنی بر سهام کوتاه‌مدت ۵ و بلندمدت ۲
-۰/۲۵۲	۱۷۷۴/۸۲۱	۲۵۷/۲۰۶	۱۱۷/۱۵۶	۷۲/۰۶	۲۸/۳۴	صندوق ۱ پیش‌تاز
-۰/۲۷۴	۱۶۶۷/۶۴۵	۲۲۰/۸۴۵	۱۲۷/۷۱	۷۲/۰۶۸	۲۸/۳۴	صندوق ۲ پیشرو
-۰/۴۷۲	۱۶۵۷/۹۸۴	۲۷۰/۷۵۶	۱۳۲/۶۷۳۶	۶۸/۸۰۱۹	۲۲/۲۹۹	شاخص کل

با توجه به نتایج جدول ۴، میزان ماقسیموم ریزش مورد انتظار برای صندوق‌های ۱۰۲ و ۲۵۰ برابر ۰/۲۷ و ۰/۰ است که این مورد برای استراتژی بین ۰/۲۵ و ۰/۴۵ گزارش شده است که نشان می‌دهد این استراتژی در موضع ریسک کمی ضعیف عمل می‌کند و حتماً باید در کنار این استراتژی از مدیریت ریسک نیز استفاده کرد. همان‌گونه که در قسمت قبلی نشان دادیم، می‌توان یک حد ضرر برای این استراتژی تعیین کرد، که اگر میزان زیان از ۱۰ درصد بیشتر شد، از آن موقعیت خارج شود. یا اینکه می‌توان از تکنیک‌های شناسایی رژیم بازار استفاده کرد و از این استراتژی فقط در زمان‌های صعودی بازار استفاده کرد؛ زیرا با توجه به نتایج عملکرد این استراتژی در زمان‌های نزولی و رنج بازار مناسب نیست.

در مرحله بعد، ما شاخص‌های اصلی ریسک و درآمد را برای استراتژی در دوره بروزنمونه محاسبه کردیم. نتیجه در جدول ۵ نشان داده شده است.

جدول ۵. شاخص‌های کلیدی ریسک و بازده

روش فیلترینگ مبتنی بر سهام کوتاه‌مدت ۹ و بلندمدت ۳	روش فیلترینگ مبتنی بر سهام کوتاه‌مدت ۸ و بلندمدت ۳	روش فیلترینگ مبتنی بر سهام کوتاه‌مدت ۵ و بلندمدت ۲	۹۵/۰۶/۰۶ ۴۰۰/۰۴/۱۸
۱/۴۲۱	۱/۱۰۵	۱/۲۰۳۵	شارپ
۳/۱۶۸	۱/۷۶۱	۱/۵۲۰	کالمر
۳/۸۸۷	۲/۶۲۰	۲/۷۳۰۱	سورتینو
-۰/۲۵۳۴	-۰/۳۸۹۶	-۰/۴۵۷۳	ماکسیموم ریزش مورد انتظار
۲۵۲۹/۲۶۵	۱۳۹۱/۴۳۸	۱۶۶۹/۲۷۵۳	بازدهی
۲/۰۴۸	۱/۰۰۵	۲/۰۸۱	چولگی
۹/۱۸۴	۱/۵۲	۸/۶۹۲	کشیدگی
۱/۰۳۱۵	۰/۷۹۱۸	۰/۸۳۵	بازدهی سالانه
۰/۴۳۸۴	۰/۴۵۸۱	۰/۴۲۸	نوسان‌های سالانه
-۰/۱۶۶	-۰/۱۷۱۰	-۰/۱۲۸	VaR۹۹٪
-۰/۰۷۸۲	-۰/۰۸۳۹	-۰/۰۶۴	VaR۹۰٪

بر اساس جدول ۵، روش فیلترینگ مبتنی بر سهام برای دوره زمانی کوتاه‌مدت ۵ و بلندمدت ۲، دارای نوسان‌های سالانه ۴۲/۸ درصد است و میزان بازدهی این روش نیز ۱۶/۶۹ و میزان بازدهی این روش نیز ۱۶/۶۹ درصد است؛ در حالی که برای دوره زمانی کوتاه‌مدت ۹ و بلندمدت ۳، نوسان‌های سالانه معادل ۴۳/۸۴ و میزان بازدهی نیز ۲۵/۲۹ درصد است. بنابراین می‌توان نتیجه گرفت که روش اول مناسب افرادی است که حاضرند ریسک کمتری را پذیرند و روش سوم مناسب افرادی که حاضرند ریسک بیشتری را پذیرند؛ چون بهزای پذیرش ریسک بیشتر، بازدهی بیشتری نیز بهدست آورده‌اند. همچنان میزان ارزش در معرض ریسک روش اول ۱۲/۸ درصد و نسبت به روش سوم که ۱۶/۶ کمتر است.

### نتیجه‌گیری و پیشنهادها

با توسعه و پیشرفت علم و فناوری، حجم زیادی از داده‌های ساختاریافته، نیمه‌ساختاریافته و بدون ساختار، هر روز با سرعتی بسیار سریع از منابع مختلفی ایجاد می‌شود. این داده‌های تولید شده از کاربران مختلف، الگوهای مشترک بسیاری

را به اشتراک می‌گذارند که می‌توان با استفاده از فیلتر و تجزیه و تحلیل این داده‌ها، توصیه‌هایی مربوط به محصول، کالا یا خدمات محبوب کاربران را انجام داد. داده‌کاوی فرایند استخراج داده‌های مربوط از حجم زیادی از داده‌ها و روش کشف و پیدا کردن الگوی مناسب از حجم زیادی از مجموعه داده‌های است. یکی از زیر مجموعه‌های داده‌کاوی سیستم توصیه‌کننده است. سیستم‌های توصیه‌کننده ابزارهای نرم‌افزاری هستند که برای ارائه پیشنهادها به کاربران، بر اساس نیازهای آن‌ها استفاده می‌شوند. در اینترنت گزینه‌های زیادی برای انتخاب اقلام مختلف وجود دارد، بنابراین نیاز به فیلتر کردن داده‌ها و تبدیل مؤثر آن داده‌ها به اطلاعات است. سیستم‌های توصیه این مسئله را با استفاده از تجزیه و تحلیل مقدار زیادی از داده‌ها برای کشف کاربران با محتواهای شخصی و خدمات حل می‌کند.

یکی از کاربردهای سیستم‌های توصیه‌کننده در حوزه ربات‌های توصیه‌کننده<sup>۱</sup> است. اینکه چه نوع سرمایه‌گذاری‌ای باید انتخاب کنم؟ چه مقدار پول باید در دارایی‌های مختلف سرمایه‌گذاری کنم؟ زمانی که ارزش سرمایه‌گذاری کم شد چه کاری باید انجام داد؟ این موارد سوال‌هایی است که اکثر افرادی که تا کنون سرمایه‌گذاری کرده‌اند یا قصد سرمایه‌گذاری دارند، از خود پرسیده‌اند. برای دستیابی به بازدهی کافی از سرمایه‌گذاری، دانش، تجربه، تخصص و تلاش لازم است.

توصیه استراتژی‌های سرمایه‌گذاری مالی، کاری پیچیده است و وظیفه توسعه دانش. به‌طور عمده، مشاوران مالی باید قبل از اینکه گزینه‌ای پیدا کنند که همه نیازها و محدودیت‌های سرمایه‌گذاران را برآورده کند با مشتریان ثروتمند خود گفت و گو کنند و از بین چندین پیشنهاد سرمایه‌گذاری، مناسب‌ترین آن را پیدا کنند. در واقع، شناختن مشتریان و ارائه پیشنهادهای سرمایه‌گذاری شخصی به آن‌ها، امروزه یک جنبه ضروری از یک استراتژی مشورتی سودمند و مؤثر است. سرمایه‌گذاری‌های فناوری اطلاعات در جهت افزایش شفافیت، ارائه گزارش بهتر و به‌موقع به مشتری است؛ اما بر روند تصمیم‌گیری سرمایه‌گذاری تأثیر نگذاشته است.

اثر انتقال قابل ملاحظه در بازار سهام بورس اوراق بهادار تهران وجود دارد و می‌توان از طریق نوسان قیمت کوتاه‌مدت بازار سهام برای پیش‌بینی عملکرد بازار استفاده کرد. در این پژوهش ما مدل پیش‌بینی سهام براساس الگوریتم فیلترینگ مشارکتی ایجاد کردیم و الگوریتم را به عنوان یک استراتژی سرمایه‌گذاری مورد بررسی و آزمون قرار دادیم. با توجه به نتایج بدست‌آمده از طریق الگوریتم برای دو دوره درون نمونه و برون نمونه، دریافتیم که این استراتژی می‌تواند بازدهی شایان توجهی نسبت به شاخص کل و حتی، صندوق‌های سهامی غیرقابل معامله داشته باشد. آنچه باید مورد تأکید قرار گیرد، این است که الگوریتم فیلترینگ مشارکتی مبتنی بر سهام، نوعی استراتژی سرمایه‌گذاری فعل و هدف آن یافتن سهام خوب برای غلبه بر بازار است؛ با این حال سرمایه‌گذاران معتقدند که سود بالا همیشه همراه با ریسک بالاست. در بیشتر سال‌ها، شاخص‌های ریسک استراتژی بیشتر از سطح متوسط است که نشان می‌دهد بازدهی این استراتژی بسیار نوسان دارد. در بازار گاوی (صعودی)، این نوسان می‌تواند بازده مازاد شایان توجهی را به همراه داشته باشد؛ اما در بازار خرسی (نزولی)، این نوسان ممکن است تمام سود و سرمایه را از بین ببرد. بنابراین در کنار استفاده از

این استراتژی، نیاز است که یک سیستم پیش‌بینی رژیم بازار وجود داشته باشد که بتواند جهت بازار آینده را پیش‌بینی کند و اگر صعودی بود، می‌توان از این استراتژی برای کسب سود مازاد از بازار استفاده کرد. همچنین برای انتخاب سهم‌های سبد توصیه‌کننده، می‌توان ابتدا معیار *hurst* را برای هر سهم پیش‌بینی کرد. اگر مقدار محاسبه شده نزدیک ۵/۰ باشد، رفتار سری زمانی مورد آزمون تصادفی و پیش‌بینی ناپذیر است. اگر مقدار محاسبه شده، نزدیک صفر باشد، رفتار سری زمانی باثبات است و اگر مقدار محاسبه شده بزرگ‌تر از ۵/۰ باشد، رفتار سری زمانی روندی است و به نظر می‌رسد برای به کارگیری چنین استراتژی‌هایی، بهتر است که سری زمانی روندی باشد. مسئله دیگر که در این پژوهش لحاظ نشده است و در پژوهش‌های آتی می‌تواند استفاده شود، در نظر گرفتن کارمزد و هزینه‌های معاملاتی و ارزیابی چنین استراتژی است. با توجه به اینکه هزینه‌های معاملاتی و کارگزاری در کشور ما بالاست، برای استفاده از چنین استراتژی‌هایی، به تغییر قوانین و مقررات و هزینه‌های معاملاتی نیاز است که استفاده از چنین استراتژی‌هایی را مقرن به صرفه کند. مسئله دیگر، بحث انتخاب دوره زمانی کوتاه‌مدت و بلندمدت است که این موضوع نیز، به تیپ شخصیتی سرمایه‌گذار و اینکه چه میزان حاضر به پذیرش ریسک است، بستگی دارد.

پیشنهاد می‌شود در پژوهش‌های آتی، این استراتژی به طور جداگانه در رژیم‌های مختلف بازار بررسی و عملکرد آن ارزیابی شود.

می‌توان این استراتژی را روی سهم‌های هر صنعت به‌طور جداگانه پیدا کرد و به‌طور مثال، از هر صنعت در هر مرحله، یک تا دو سهم انتخاب کرد (ما پرتفوی ۵ سهمی تشکیل داده بودیم) و بعد با استفاده از سهم‌های انتخاب شده در هر مرحله، برای هر صنعت پرتفوی را تشکیل داد.

استراتژی ما به صورت پرتفوی هموزن بود و هم‌زمان دارایی بین هر ۵ سهم تقسیم شد، می‌توان در پژوهش‌های آتی، سایر استراتژی‌های وزن‌دهی را نیز با این روش ترکیب و عملکرد استراتژی نهایی را ارزیابی کرد. همچنین پژوهشگران می‌توانند با اضافه کردن متغیرهای نقدشونگی و حجم به استراتژی، عملکرد آن را بررسی کنند.

## منابع

- سارنج، علیرضا و نوراحمدی، مرضیه (۱۳۹۵). تخمین ارزش در معرض ریسک (VaR) و ریزش مورد انتظار (ES) با استفاده از رویکرد ارزش فرین شرطی در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۱۱(۳)، ۴۳۷-۴۶۰.
- دولو، مريم و طبرسا، بهاره (۱۳۹۹). مومتووم سبکی و منشاً بروز آن. *تحقیقات مالی*، ۲۲(۳)، ۳۲۰-۳۴۲.
- نوراحمدی، مرضیه و صادقی، حجت‌الله (۱۴۰۱). گونه‌شناسی شخصی‌سازی در سیستم‌های توصیه‌کننده. *مدیریت نوآوری و راهبردهای عملیاتی*، ۱۳(۱)، ۱۲-۳۱.

نوراحمدی، مرضیه و صادقی، حجت‌الله. (۱۴۰۱). یادگیری ماشین مبتنی بر رویکرد سلسله مرتبی برابری ریسک (HRP): مطالعه موردی پرتفلیو سهام متشکل از ۳۰ شرکت برتر بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۵(۲)، ۲۳۶-۲۵۶.

ولیدی، جواد؛ نجفی، امیر عباس و ولیدی، علیرضا. (۱۳۸۹). انتخاب برخط سبد سرمایه‌گذاری به کمک الگوریتم‌های تبعیت از بازنده. *تحقیقات مالی*، ۲۲(۳)، ۴۰۸-۴۲۷.

## References

- Adomavicius, G. & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749.
- Avramov, D., Kaplanski, G. & Levy, H. (2018). Talking Numbers: Technical versus fundamental investment recommendations. *Journal of Banking & Finance*, 92, 100–114.
- Bag, V. & Kulkarni, U. V. (2017). Stock Price Trend Prediction and Recommendation using Cognitive Process. *International Journal of Rough Sets and Data Analysis (IJRSDA)*, 4(2), 36–48.
- Baldauf, B. & Santoni, G. J. (1991). Stock price volatility: some evidence from an ARCH model. *The Journal of Futures Markets (1986-1998)*, 11(2), 191.
- Barber, B. M. & Odean, T. (2013). The behavior of individual investors. In *Handbook of the Economics of Finance* (Vol. 2, pp. 1533–1570). Elsevier.
- Breese, J. S., Heckerman, D. & Kadie, C. (2013). *Empirical analysis of predictive algorithms for collaborative filtering*. ArXiv Preprint ArXiv:1301.7363.
- Chavarnakul, T. & Enke, D. (2008). Intelligent technical analysis based equivoque charting for stock trading using neural networks. *Expert Systems with Applications*, 34(2), 1004–1017.
- Chong, T. T.L. & Ng, W.K. (2008). Technical analysis and the London stock exchange: testing the MACD and RSI rules using the FT30. *Applied Economics Letters*, 15(14), 1111–1114.
- Davallou, M. & Tabarsa, B. (2020). The Style Momentum and Its Origin. *Financial Research Journal*, 22(3), 320–342. <https://doi.org/10.22059/frj.2020.288887.1006924>. (in Persian)
- De Campos, L. M., Fernández-Luna, J. M., Huete, J. F., & Rueda-Morales, M. A. (2010). Combining content-based and collaborative recommendations: A hybrid approach based on Bayesian networks. *International journal of approximate reasoning*, 51(7), 785-799.
- de Oliveira, F. A., Nobre, C. N. & Zarate, L. E. (2013). Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index—Case study of PETR4, Petrobras, Brazil. *Expert Systems with Applications*, 40(18), 7596–7606.
- De Rossi, G., Kolodziej, J., & Brar, G. (2020). A recommender system for active stock selection. *Computational Management Science*, 17(4), 517-547.
- Dickson, G. K. (2015). *Assessing the Performance of Active and Passive Trading On the Ghana Stock Exchange*. University of Ghana.
- Dowd, K. (2007). *Measuring market risk*. John Wiley & Sons.

- Du, Y. & Li, S. (2004). Industrial value chain: the innovative format of value strategy [J]. *Studies in Science of Science*, 5.
- Ewing, B. T. (2002). The transmission of shocks among S&P indexes. *Applied Financial Economics*, 12(4), 285–290.
- Fama, E. F. (1995). Random walks in stock market prices. *Financial Analysts Journal*, 51(1), 75–80.
- Fernandez Rodriguez, F., Sosvilla-Rivero, S. & Andrada Félix, J. (1999). *Technical analysis in the Madrid stock exchange*.
- Guo, H. & Savickas, R. (2006). Idiosyncratic volatility, stock market volatility, and expected stock returns. *Journal of Business & Economic Statistics*, 24(1), 43–56.
- Hsu, Y.T., Liu, M.C., Yeh, J. & Hung, H.-F. (2009). Forecasting the turning time of stock market based on Markov–Fourier grey model. *Expert Systems with Applications*, 36(4), 8597–8603.
- Jondeau, E. & Rockinger, M. (2006). The copula-garch model of conditional dependencies: An international stock market application. *Journal of International Money and Finance*, 25(5), 827–853.
- Karolyi, G. A. (1995). A multivariate GARCH model of international transmissions of stock returns and volatility: The case of the United States and Canada. *Journal of Business & Economic Statistics*, 13(1), 11–25.
- Kimoto, T., Asakawa, K., Yoda, M. & Takeoka, M. (1990). Stock market prediction system with modular neural networks. *1990 IJCNN International Joint Conference on Neural Networks*, 1–6.
- Koutmos, G. & Booth, G. G. (1995). Asymmetric volatility transmission in international stock markets. *Journal of International Money and Finance*, 14(6), 747–762.
- Li, G.-D., Yamaguchi, D. & Nagai, M. (2008). The development of stock exchange simulation prediction modeling by a hybrid grey dynamic model. *The International Journal of Advanced Manufacturing Technology*, 36(1–2), 195–204.
- Musto, C., Semeraro, G., Lops, P., De Gemmis, M. & Lekkas, G. (2015). Personalized finance advisory through case-based recommender systems and diversification strategies. *Decision Support Systems*, 77, 100–111.
- Nti, I. K., Adekoya, A. F., Weyori, B. A., Ballings, M., Van den Poel, D., Hespeels, N. & Gryp, R. (2015). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 42(20), 1–51.
- Nourahmadi, M. & Sadeqi, H. (2022). Typology of personalization in recommender systems. *Innovation Management and Operational Strategies*, 3(1), 12–31. [\(in Persian\)](https://doi.org/10.22105/imos.2021.290478.1117)
- Nourahmadi, M. & Sadeqi, H. (2022). A Machine Learning-Based Hierarchical Risk Parity Approach: A Case Study of Portfolio Consisting of Stocks of the Top 30 Companies on the Tehran Stock Exchange *Financial Research Journal*, 25(2), 236-256. *(in Persian)*

- Papagelis, M., Plexousakis, D. & Kutsuras, T. (2005). Alleviating the sparsity problem of collaborative filtering using trust inferences. *International Conference on Trust Management*, 224–239.
- Paranjape-Voditel, P. & Deshpande, U. (2013). A stock market portfolio recommender system based on association rule mining. *Applied Soft Computing*, 13(2), 1055–1063.
- Patel, B., Desai, P. & Panchal, U. (2017). Methods of recommender system: a review. *2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS)*, 1–4.
- Patel, H. R. (2019). Analytical Study for Hybrid Method based Stock Recommendation. *Journal of the Gujarat Research Society*, 21(6), 227–234.
- Ricci, F., Rokach, L. & Shapira, B. (2011). Introduction to recommender systems handbook. In *Recommender systems handbook* (pp. 1–35). Springer.
- Saranj, A. & Nourahmadii, M. (2016). Estimating of value at risk and expected shortfall by using conditional extreme value approach in Tehran Securities Exchange. *Financial Research Journal*, 18(3), 437–460. <https://doi.org/10.22059/jfr.2016.62450>. (in Persian)
- Schmitz, H. & Humphrey, J. (2000). *Governance and Upgrading: Linking Industrial Cluster and Global Value Chain Research*. (Vol. 120, pp. 139-170). Brighton: Institute of Development Studies.
- Shiller, R. (1989). *Market Volatility* MIT Press. Cambridge Mass.
- Song, F. M. (1994). A two-factor ARCH model for deposit-institution stock returns. *Journal of Money, Credit and Banking*, 26(2), 323–340.
- Su, C.-H. & Cheng, C.-H. (2016). A hybrid fuzzy time series model based on ANFIS and integrated nonlinear feature selection method for forecasting stock. *Neurocomputing*, 205, 264–273.
- Sureshkumar, K. K. & Elango, N. M. (2011). An efficient approach to forecast Indian stock market price and their performance analysis. *International Journal of Computer Applications*, 34(5), 44–49.
- Van Horne, J. C. & Parker, G. G. C. (1967). The random-walk theory: an empirical test. *Financial Analysts Journal*, 23(6), 87–92.
- Validi, J., Najafi, A. A. & Validi, A. (2020). Online Portfolio Selection Based on Follow-the-Loser Algorithms. *Financial Research Journal*, 22(3), 320–342. <https://doi.org/10.22059/frj.2020.288887.1006924>. (in Persian)
- Vismayaa, V., Pooja, K. R., Alekhya, A., Malavika, C. N., Nair, B. B. & Kumar, P. N. (2019). Classifier Based Stock Trading Recommender Systems for Indian stocks: An Empirical Evaluation. *Computational Economics*, 1–23.
- Wei, L.Y., Chen, T.L. & Ho, T.H. (2011). A hybrid model based on adaptive-network-based fuzzy inference system to forecast Taiwan stock market. *Expert Systems with Applications*, 38(11), 13625–13631.

- White, H. (1988). Economic prediction using neural networks: The case of IBM daily stock returns. *ICNN*, 2, 451–458.
- Xue, J., Zhu, E., Liu, Q. & Yin, J. (2018). Group recommendation based on financial social network for robo-advisor. *IEEE Access*, 6, 54527–54535.
- Yin, L. & Deng, Y. (2018). Measuring transferring similarity via local information. *Physica A: Statistical Mechanics and Its Applications*, 498, 102–115.
- Yin, L., Zheng, H., Bian, T. & Deng, Y. (2017). An evidential link prediction method and link predictability based on Shannon entropy. *Physica A: Statistical Mechanics and Its Applications*, 482, 699–712.
- Zheng, Z., Gao, Y., Yin, L. & Rabarison, M. K. (2019). Modeling and analysis of a stock-based collaborative filtering algorithm for the Chinese stock market. *Expert Systems with Applications*, 113006.
- Zibriczky12, D. (2016). Recommender systems meet finance: a literature review. In *Proc. 2nd Int. Workshop Personalization Recommender Syst* (pp. 1-10).