

Prediction of Stock Market Behavior Based on Artificial Neural Networks through Intelligent Ensemble Learning Approach

Mohammad Taghi Faghihi Nezhad

Ph.D. Student in Information Technology Engineering, Faculty of Engineering, Qom University, Qom, Iran. E-mail: mfaghihi@pnu.ac.ir

Behrouz Minaei-Bidgoli

*Corresponding author, Associate Prof., School of Computer Engineering, Iran University of Science and Technology, Tehran, Iran. E-mail: b_minaei@iust.ac.ir

Abstract

Objective: Accurate forecasting of stock market behavior is invaluable for traders. Forecasting financial time series is among the important and challenging problems and researchers try to extract hidden patterns to predict the future behavior of the stock market. The purpose of this paper is to provide an intelligent model to predict stock market behavior.

Methods: This paper employs ensemble learning (EL) algorithm model using neural network base learners to increase the accuracy. In order to consider the direction of price change in the stock price forecasting, a two-stage structure was used. In the first stage, the next direction of the stock price (increase or decrease) was predicted and then it was employed to forecast the price.

Results: The most important challenges of the proposed models in the stock market were the accuracy of the results and how to increase the forecasting efficiently. Research in this field has paid little attention to the prediction of the direction of the next movement of stock price, while it is very important regarding the profitability. The use of artificial intelligence-based models has shown that the stock market is predictable despite its uncertain and unstable nature.

Conclusion: The evaluation of results in stock market dataset shows that the proposed model suggests higher accuracy compared to other models in the literature. In addition, it can overcome the market fluctuations and can be used as a reliable and applicable model in the stock markets.

Keywords: Estimating the direction of price movement, Ensemble learning, Intelligent prediction models, Neural network, Stock price prediction.

Citation: Faghihi Nezhad, M.T., Minaei-Bidgoli, B. (2018). Prediction of Stock Market Behavior Based on Artificial Neural Networks through Intelligent Ensemble Learning Approach. *Industrial Management Journal*, 10(2), 315-334. (in Persian)

Industrial Management Journal, 2018, Vol. 10, No.2, pp. 315-334

DOI: 10.22059/imj.2018.255079.1007412

Received: September 21, 2017; Accepted: January 31, 2018

© Faculty of Management, University of Tehran

پیش‌بینی رفتار بازار سهام بر اساس شبکه‌های عصبی مصنوعی با رویکرد یادگیری جمعی هوشمند

محمد تقی فقیهی نژاد

دانشجوی دکتری مهندسی فناوری اطلاعات، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران. رایانامه: mfaghihi@pnu.ac.ir

بهروز مینایی بیدگلی

* نویسنده مسئول، دانشیار گروه هوش مصنوعی، دانشکده مهندسی کامپیوتر، دانشگاه علم و صنعت ایران، تهران، ایران. رایانامه: b_minaei@iust.ac.ir

چکیده

هدف: پیش‌بینی دقیق بازار سهام برای معامله‌گران این بازار ارزشمند است. پیش‌بینی سری‌های زمانی مالی از دسته مسائل چالشی و مهم در پیش‌بینی است و پژوهشگران تلاش می‌کنند که الگوهای پنهان را برای پیش‌بینی آینده بازار سهام استخراج کنند. هدف این مقاله ارائه یک مدل هوشمند برای پیش‌بینی رفتار بازار سهام است.

روش: این مقاله، برای افزایش دقت از مدلی بر مبنای الگوریتم‌های یادگیری جمعی با مدل‌های پایه شبکه‌های عصبی استفاده می‌کند. برای در نظر گرفتن جهت تغییر قیمت در پیش‌بینی، ساختار دومرحله‌ای به کار رفته است. در مرحله نخست، جهت بعدی حرکت قیمت سهام (افزایش یا کاهش) پیش‌بینی شده و از آن برای پیش‌بینی قیمت در مرحله دوم استفاده شده است.

یافته‌ها: دقت نتایج و افزایش بازده پیش‌بینی، مهم‌ترین چالش مدل‌های پیشنهادشده در بازار سهام به‌شمار می‌رود. نکته مهم برای سودآوری معاملات، توجه به جهت تغییر قیمت سهام در پیش‌بینی قیمت آن است که در مدل‌های پیش‌بینی به این موضوع توجه کمتری شده است. مدل پیشنهادی با استفاده از روش‌های مبتنی بر هوش مصنوعی نشان می‌دهد که پیش‌بینی رفتار بازار سهام با وجود ماهیت نوسانی و ناپایدار آن، امکان‌پذیر است.

نتیجه‌گیری: نتایج معیارهای ارزیابی روی داده‌های واقعی قیمت سهام نشان می‌دهد مدل پیشنهاد شده در مقایسه با سایر روش‌ها، با دقت بیشتری می‌تواند بر نوسان‌های بازار غلبه کرده و به‌عنوان روش قابل اطمینان و عملی در بازارهای سهام به کار گرفته شود.

کلیدواژه‌ها: پیش‌بینی تغییر جهت قیمت، پیش‌بینی قیمت سهام، شبکه عصبی، یادگیری جمعی، مدل‌های پیش‌بینی هوشمند.

استناد: فقیهی نژاد، محمد تقی؛ مینایی، بهروز (۱۳۹۷). پیش‌بینی رفتار بازار سهام بر اساس شبکه‌های عصبی مصنوعی با رویکرد یادگیری جمعی هوشمند. *فصلنامه مدیریت صنعتی*، ۱۰(۱)، ۳۱۵-۳۳۴.

فصلنامه مدیریت صنعتی، ۱۳۹۷، دوره ۱۰، شماره ۲، صص. ۳۱۵-۳۳۴

DOI: 10.22059/imj.2018.255079.1007412

دریافت: ۱۳۹۶/۰۶/۳۰، پذیرش: ۱۳۹۶/۱۱/۱۱

© دانشکده مدیریت دانشگاه تهران

مقدمه

پیش‌بینی دقیق بازار سهام برای معامله‌گران این بازار ارزشمند است. پیش‌بینی سری‌های زمانی مالی از دسته مسائل پرچالش و مهم در پیش‌بینی است و پژوهشگران تلاش می‌کنند الگوهای پنهان را برای پیش‌بینی آینده بازار سهام استخراج کنند (لی، یانگ، زو و ژو، ۲۰۱۷). مهم‌ترین چالش در این موضوع، افزایش بازده پیش‌بینی و دقت نتایج است که محققان با ارائه مدل‌ها و روش‌های مختلف، برای بهبود دادن آن تلاش می‌کنند (گورسن، کیاکتلو و دایم، ۲۰۱۱). البته با توجه به ماهیت نوسانی و ناپایدار بازار سهام، مدل‌ها در پیش‌بینی با محدودیت‌ها و مشکلاتی مواجه می‌شوند (سی و یین، ۲۰۱۳). اغلب محققان در این مدل‌ها به پیش‌بینی قیمت پرداخته‌اند و برای ارزیابی از معیارهایی که نزدیکی قیمت پیش‌بینی شده به قیمت واقعی را نشان می‌دهد، بهره برده‌اند (یان، ژو، وانگ و ژانگ، ۲۰۱۷). چالش دیگر در مدل‌های پیش‌بینی، بی‌توجهی به پیش‌بینی روند حرکت قیمت سهام در پیش‌بینی قیمت است. این نکته می‌تواند موجب تصمیم‌گیری اشتباه و ضرر برای سرمایه‌گذاران شود. برای نمونه، اگر قیمت یک سهم در حال حاضر ۱۰۰ دلار، قیمت پیش‌بینی شده ۱۰۰/۱ دلار و قیمت واقعی بعدی ۹۹/۹ دلار باشد، در این مدل قیمت با دقت مناسب و اختلاف ۰/۱ درصد پیش‌بینی شده است. معامله‌گر با توجه به پیش‌بینی افزایش قیمت، وارد موقعیت خرید این سهم می‌شود، در حالی که قیمت واقعی کاهش یافته و موجب ضرر خواهد شد. دلیل این رخداد، بی‌توجهی به روند تغییر قیمت سهم در پیش‌بینی قیمت آن است. برای غلبه بر این چالش‌ها، پس از بررسی تحقیقات انجام شده در این حوزه، محققان این پژوهش مدلی پیشنهاد کرده‌اند که از یک مدل یادگیری جمعی با مدل‌های پایه هوشمند استفاده می‌کند و می‌تواند بهبود نتایج پیش‌بینی را به حداکثر برساند. همچنین برای در نظر گرفتن جهت تغییر قیمت در پیش‌بینی قیمت سهام، از ساختار دویبخشی استفاده شده که در بخش اول جهت بعدی حرکت قیمت سهام (افزایش یا کاهش) را پیش‌بینی کرده و از آن برای پیش‌بینی قیمت در مرحله دوم بهره می‌برد.

ادامه پژوهش به این صورت ساختار بندی شده است؛ در پیشینه پژوهش، قابلیت پیش‌بینی بازار سهام و مدل‌های مختلف پیش‌بینی بررسی شده است. در روش‌شناسی پژوهش، مدل پیشنهاد شده دوحله‌ای بر اساس یادگیری جمعی و استفاده از مدل‌های هوشمند معرفی می‌شود. در یافته‌های پژوهش، نتایج تجربی ارائه شده و مقایسه‌ای میان مدل پیشنهاد شده با سایر مدل‌ها انجام می‌گیرد و در آخرین بخش به بحث و نتیجه‌گیری پرداخته خواهد شد.

پیشینه نظری پژوهش

دو فرضیه اصلی برای پیش‌بینی بازار سهام وجود دارد. بر اساس فرضیه بازار کارا، قیمت‌های بازار به‌طور کامل تمام اطلاعات موجود را نشان می‌دهد و قیمت‌ها با اطلاعات جدید تغییر می‌کنند. بر اساس این فرضیه، بازده بیشتر از طریق انتخاب سهام به روش‌های هوشمندانه یا تکنیک‌های دیگر امکان‌پذیر نیست. تنها راهی که خریداران می‌توانند سود بیشتری کسب کنند، انتخاب سهام با ریسک بیشتر یا به‌صورت شانس است (فاما و مالکیل، ۱۹۷۰). در هر بازار کارا، اگر انتظارات و اطلاعات همه شرکت‌کنندگان از بازار در قیمت‌ها منعکس شود، نوسان قیمت‌ها پیش‌بینی‌ناپذیر است. نظریه دیگری که با این نظریه سازگار است، نظریه گام تصادفی نام دارد که بر اساس آن، روند تغییرات قیمت سهام به‌صورت تصادفی بوده و پیش‌بینی‌پذیر نیست (فاما، ۱۹۹۵). به هر حال برخی مطالعات اخیر، رفتار تصادفی قیمت سهام را رد

می‌کنند (لو و مک‌کینلی، ۱۹۸۸). همچنین کاربرد هوش مصنوعی در مسائل مالی موجب تقویت این نظریه شده که بازار ممکن است همیشه کاملاً کارا نباشد و بتوان قیمت‌های آینده را از داده‌های تاریخی با تکنیک‌های مختلف استخراج کرد (تسای، لین، بین و چن، ۲۰۱۱؛ زونگ و انکه، ۲۰۱۷).

برای پیش‌بینی بازار سهام به کمک داده‌های تاریخی، روش‌های مختلفی وجود دارد. در یک طبقه‌بندی این روش‌ها در دو گروه خطی و غیرخطی قرار می‌گیرند و در نوع دیگر، به روش‌های یادگیری ماشین و آماری دسته‌بندی می‌شوند؛ اما دسته‌بندی مناسب، گروه‌بندی آنها به روش‌های هوشمند و کلاسیک است. در روش‌های پیش‌بینی کلاسیک، فرض بر این است که مقادیر آینده قیمت، روند خطی مقادیر گذشته را دنبال می‌کند و مدل‌های رگرسیون^۱ گارچ^۲ و آریما^۳ در این دسته جای دارند. شبکه‌های عصبی^۴، منطق فازی^۵، ماشین‌های بردار پشتیبان^۶ و مدل‌های یادگیری جمعی^۷ در دسته روش‌های هوشمند قرار می‌گیرند (کوالکانت، برازیلرو، سوزا و الویرا، ۲۰۱۶). نتیجه مقایسه‌ها نشان داده است که روش‌های هوشمند با غلبه بر محدودیت‌های موجود در مدل‌های خطی در مقایسه با روش‌های کلاسیک، برای استخراج مدل از داده‌ها توانایی بهتر و برای پیش‌بینی دقت بیشتری دارند (آدی، ادموی و آیو، ۲۰۱۴).

در سال‌های اخیر، بیشتر مطالعات انجام‌شده برای پیش‌بینی بازار سهام بر روش‌های هوشمند متمرکزند (تکاچ و ورنر، ۲۰۱۶) و در بین آنها شبکه عصبی بیشترین کاربرد را داشته (اتسلاکیس و والانیس، ۲۰۰۹) و دارای بازده بهتری نسبت به سایر مدل‌ها بوده است (تکاچ و ورنر، ۲۰۱۶). از شبکه عصبی برای پیش‌بینی در مواردی مانند ورشکستگی شرکت‌ها در بازار سهام نیز استفاده می‌شود (نیکبخت و شریفی، ۱۳۸۹). با وجود پیچیده بودن پیش‌بینی در بازار سهام، نتیجه پژوهش‌ها نشان داده است که شبکه عصبی با یک لایه مخفی، می‌تواند برای مدل‌سازی یک سیستم پیچیده با دقت مدنظر کافی باشد (چاوین و راملهارت، ۱۹۹۵).

پیشینه تجربی

استفاده از مدل‌های هوشمند در پیش‌بینی بازار سهام را می‌توان به چند گروه دسته‌بندی کرد. در گروه اول، از یک مدل منفرد برای پیش‌بینی استفاده می‌شود. مدل‌های منفرد دو نوع هستند: ۱. مدل‌هایی که در آن فقط از یک تکنیک استفاده شده است و ۲. مدل‌هایی که از چند تکنیک برای بهبود دقت پیش‌بینی استفاده می‌کنند. نمونه استفاده از مدل‌های منفرد با یک تکنیک، پژوهشی است که ب(کرا، بویاکیگلو و بایکان، ۲۰۱۱) برای پیش‌بینی جهت حرکت شاخص بورس استانبول انجام داده‌اند و در آن دقت دو مدل شبکه عصبی و ماشین‌های بردار پشتیبان را با هم مقایسه کرده‌اند. همچنین (تیکنور، ۲۰۱۳) با هدف پیش‌بینی قیمت سهام، شبکه عصبی بیزین را با معیار ارزیابی درصد میانگین قدر مطلق خطا (MAPE)^۸ کرده است.

1. Regression
2. ARCH
3. ARIMA
4. Neural Network
5. Fuzzy Logic
6. Support Vector Machines
7. Ensemble Learning algorithm
8. Mean Absolute Percentage Error (MAPE)

مدل‌های منفرد مانند شبکه‌های عصبی که از یک تکنیک استفاده می‌کنند، در مقایسه با مدل‌های کلاسیک، دقت را افزایش می‌دهند، اما شبکه‌های عصبی به دلیل مشکلاتی همچون افتادن در بهینه محلی^۱ و بیش‌برازش^۲، دقت پیش‌بینی را دچار چالش می‌کنند. مطالعات نشان داده است که استفاده از سایر تکنیک‌های هوشمند همراه با شبکه عصبی برای استفاده از مزیت‌های هر یک و پوشش کاستی‌های دیگری، موجب افزایش دقت پیش‌بینی می‌شود (تک‌اچ و ورنر، ۲۰۱۶). پژوهش‌های حسن (۲۰۰۹) با استفاده از زنجیره مارکوف، شبکه عصبی و الگوریتم ژنتیک؛ منجمی، ابزری و رعیتی شوازی (۱۳۸۸) با استفاده از شبکه عصبی - فازی و الگوریتم‌های ژنتیک؛ اسدی، هداوندی، مهمان‌پذیر و نخستین (۲۰۱۲) با استفاده از شبکه عصبی و الگوریتم ژنتیک برای بهبود آموزش شبکه عصبی؛ چانگ (۲۰۰۸) با استفاده از مدل استنتاج فازی تاکاگی - سوگونو همراه با الگوریتم تبرید^۳ برای بهبود آموزش پارامترها و اصفهانی‌پور و آقامیری، (۲۰۱۰) با استفاده از سیستم نرو فازی^۴ همراه با خوشه‌بندی فازی برای مشخص کردن قوانین، در این دسته قرار می‌گیرند.

گروه دوم مدل‌های هوشمند در پیش‌بینی بازار سهام، از ترکیب چند مدل منفرد ایجاد می‌شوند که مدل‌های ترکیبی نام دارند. نمونه این مدل‌ها ترکیب مدل شبکه عصبی با مدل‌های کلاسیک است. (ژانگ، ۲۰۰۳) ترکیب شبکه عصبی به‌عنوان مدل غیرخطی و آریمای به‌عنوان مدل خطی و (خاشعی و بیجاری، ۲۰۰۹) ترکیب آریمای و شبکه عصبی و منطق فازی را برای همین منظور به کار برده‌اند.

سعیدی و محمدی (۱۳۹۰) ترکیب شبکه عصبی و مدل گارچ را پس از بررسی مجموعه وسیعی از مدل‌های گروه ناهمسازی و آریانس شرطی و ترکیب خروجی آنها توسط شبکه عصبی، به کار برده است. ادیکاری (۲۰۱۵) با ترکیب خطی مدل‌ها که وزن هر مدل از طریق شبکه‌های عصبی تعیین می‌شود، به یک مدل ترکیبی کارا دست یافته است. در این پژوهش‌ها عملکرد مدل پیشنهاد شده با مدل‌های منفرد موجود در ترکیب آن مقایسه شده است و ارزیابی‌ها نشان می‌دهد مدل‌های ترکیبی عملکرد بهتری دارند.

گروه سوم مدل‌های هوشمند در پیش‌بینی بازار سهام، گروهی از مدل‌های پایه هوشمند را در یک مدل واحد تجمیع کرده و از الگوریتم‌های یادگیری جمعی استفاده می‌کنند. مدل‌های ترکیبی از تعداد محدود (در حد ۲ تا نهایت ۱۰) مدل با ماهیت‌های متفاوت تشکیل شده‌اند، در حالی که مدل‌های مبتنی بر یادگیری جمعی از تعداد زیادی (حتی بالاتر از ۱۰۰) مدل پایه هم‌نوع تشکیل شده و هر مدل از بخشی از داده‌های آموزشی برای آموزش استفاده می‌کند. در سال‌های اخیر، از این روش‌ها برای افزایش دقت مدل‌های رگرسیونی بسیار استقبال شده و نتایج به‌دست آمده در کاربردهای مختلف کارایی آن را به اثبات رسانده است. در این روش‌ها خروجی مدل‌ها به‌وسیله روش‌های مختلف تجمیع می‌شود تا علاوه بر دقت بیشتر، نتایج مطمئن‌تر و پایدارتر شوند. ادبیات موضوع به‌صورت گسترده‌ای نشان می‌دهد که به‌طور کلی، تجمیع پیش‌بینی مجموعه‌ای از شبکه‌های عصبی به بهبود دقت پیش‌بینی و پایداری نتایج منجر خواهد شد. این نتایج دقت بهتری نسبت به مدل‌های تشکیل‌دهنده آنها دارد (دیتریش، ۲۰۰۰؛ تسای، لین، بین و چن، ۲۰۱۱؛ ژائو، ژائو، لو و وانگ،

1. Local optimum
2. Over fitting
3. Simulated Annealing
4. Neuro Fuzzy

۲۰۱۳؛ بالینگ، وان دن پل، هس پیلس و گریپ، ۲۰۱۵؛ مک نیکتا، ۲۰۱۶؛ لین، وانگ، ژی و ژانگ، ۲۰۱۷). همچنین بر اساس نتیجه پژوهش‌ها، شرط لازم و کافی برای فزونی دقت یک یادگیرنده جمعی از یادگیرنده‌های عضو، دقیق بودن و تنوع در رده‌بندی‌های عضو است. دقیق بودن به معنای دقت بهتر از یادگیرنده تصادفی است (هانسن، ۱۹۹۰). مقاله‌های مرتبط با مدل‌های هوشمند پیش‌بینی بازار سهام همراه با هدف پیش‌بینی و معیار ارزیابی عملکرد در جدول ۱ نمایش داده شده است. همچنین در این جدول، تکنیک‌های استفاده‌شده در این مقاله‌ها، دسته‌بندی مدل‌ها و نتیجه مقایسه با مدل‌های دیگر مشاهده می‌شود.

جدول ۱. مقاله‌های مرتبط با روش‌های پیش‌بینی و دسته‌بندی انواع این روش‌ها

پژوهشگر	هدف پیش‌بینی	معیار عملکرد	تکنیک	۱	۲	۳	۴	مقایسه با مدل‌های دیگر
کرا (۲۰۱۱)	جهت بازار	hit ratio	ماشین بردار پشتیبان - شبکه عصبی	✓				سایر مدل‌های شبکه عصبی
تیکور (۲۰۱۳)	قیمت سهام	MAPE	شبکه عصبی بیزین	✓				شبکه عصبی و ژنتیک
حسن (۲۰۰۷)	قیمت سهام	MAPE	ترکیب زنجیره مارکوف، شبکه عصبی و ژنتیک		✓			شبکه عصبی، آریم
چانگ (۲۰۰۸)	قیمت سهام	MAPE	مدل سوگنو بهبودیافته با الگوریتم تبرید		✓			شبکه عصبی، آنالیز رگرسیون
اصفهان‌ای (۲۰۱۰)	قیمت سهام	MAPE	نرو فازی و خوشه‌بندی فازی		✓			شبکه عصبی، سوگنو + الگوریتم تبرید
اسدی (۲۰۱۲)	قیمت سهام	MAPE, POCID	شبکه عصبی و ژنتیک		✓			نرو فازی، شبکه عصبی
قاسمی (۲۰۱۷)	قیمت سهام	MAPE	عصبی - کوکو سرچ		✓			عصبی - ژنتیک، عصبی - ازدحام ذرات
ژانگ (۲۰۰۳)	قیمت سهام	MSE	ترکیب شبکه عصبی و آریم			✓		شبکه عصبی، آریم
خاشعی (۲۰۰۹)	قیمت سهام	MAPE	ترکیب شبکه عصبی و آریم و منطق فازی			✓		شبکه عصبی، آریم
وانگ (۲۰۱۲)	قیمت سهام	MAPE	ترکیب وزن‌دار آریم و شبکه عصبی بازگشتی			✓		آریم، شبکه عصبی
ادیکاری (۲۰۱۵)	جهت بازار	MAPE	ترکیب خطی از شبکه‌های عصبی			✓		شبکه عصبی
پاتل (۲۰۱۵)	قیمت سهام	MAPE	رگرسیون بردار پشتیبان + عصبی			✓		رگرسیون بردار پشتیبان، عصبی
چیو (۲۰۱۶)	بازده سهام	MSE	عصبی - ژنتیک و عصبی - تبرید			✓		شبکه عصبی
تسای (۲۰۱۱)	جهت بازار	accuracy	تجمیع مدل‌های پایه به دو روش بگینگ و رأی‌گیری				✓	شبکه عصبی، رگرسیون لجستیک
بالینگ (۲۰۱۳)	جهت بازار	accuracy	تجمیع مدل‌های پایه با جنگل تصادفی و ادا بوست				✓	شبکه عصبی، ماشین بردار پشتیبان
ژائو (۲۰۱۳)	قیمت سهام	MAPE	تجمیع ۳ مدل شبکه عصبی با الگوریتم‌های بهینه‌سازی				✓	سه مدل متفاوت شبکه عصبی
لین (۲۰۱۷)	قیمت سهام	MAPE	تجمیع مدل‌های پایه با روش جنگل تصادفی				✓	مدل‌های پایه ماشین یادگیری شدید

۴. مدل‌های یادگیری جمعی

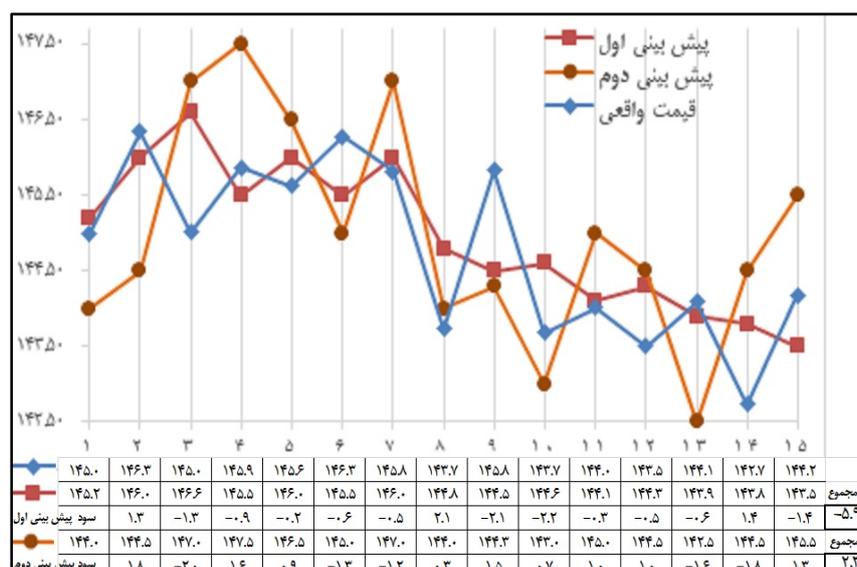
۲. مدل‌های منفرد (چند تکنیک) ۳. مدل‌های ترکیبی

۱. مدل‌های منفرد (تک تکنیک)

چالش‌های پیش‌بینی بازار سهام

محققان تلاش کرده‌اند که با ارائه روش‌های متنوع، توانایی مدل‌های پیشنهادی را در افزایش دقت پیش‌بینی بازار سهام نمایش دهند. با توجه به نتایج به‌دست آمده از مرور ادبیات، دقت بیشتر الگوریتم‌های یادگیری جمعی همراه با قابلیت اطمینان و پایداری بیشتر، در پیش‌بینی بازار سهام تأیید شده است. به همین دلیل، در مدل پیشنهاد شده برای بهره‌بردن از این مزیت‌ها، الگوریتم‌های یادگیری جمعی استفاده شده است. همچنین، برای اینکه نتایج مدل پیش‌بینی بازار سهام بتواند در محیط واقعی استفاده شود و معاملات بر مبنای آن به سود بینجامد، باید در پیش‌بینی قیمت به جهت حرکت قیمت توجه شود. محققان در مدل‌های موجود، اغلب به پیش‌بینی قیمت در بازار سهام پرداخته‌اند و برای ارزیابی، از معیارهایی مانند MAPE که نزدیکی قیمت پیش‌بینی شده به قیمت واقعی را نشان می‌دهد، استفاده کرده‌اند (جدول ۱) و به موضوع روند تغییرات قیمت و نقش آن در سودآوری معاملات، بی‌توجه بوده‌اند.

در شکل ۱ این موضوع با ذکر نمونه توضیح داده شده است. شکل ۱، قیمت سهام شرکت اپل را همراه با دو پیش‌بینی قیمت نمایش می‌دهد. MAPE محاسبه شده در پیش‌بینی نخست برابر ۰/۴۵ درصد است. قیمت روز دوم ۱۴۶/۳۴ و قیمت پیش‌بینی شده برای روز سوم ۱۴۶/۶ است. با توجه به اینکه قیمت افزایشی پیش‌بینی شده، معامله‌گر وارد موقعیت خرید می‌شود، در حالی که قیمت واقعی در روز سوم (۱۴۵/۰۱) نسبت به روز قبل کاهش یافته است که این موجب ضرر ۱/۳ دلار می‌شود. بر اساس این پیش‌بینی، ضرر معامله روزانه پس از ۱۴ روز به ۵/۹ دلار خواهد رسید. خطای MAPE محاسبه شده برای دومین پیش‌بینی ۰/۸۷ درصد مشاهده می‌شود که کمابیش ۹۰ درصد بیش از خطای نخستین پیش‌بینی است، اما معامله روزانه بر اساس این پیش‌بینی به سود ۲/۳ دلاری طی ۱۴ روز منجر خواهد شد. در نخستین نمونه، روند تغییر قیمت به پیروی از آخرین تغییر جهت قیمت، در جهت افزایش یا کاهش است و در واقع، به جای مدل پیش‌بینی کننده به یک مدل تعقیب کننده تغییر جهت قیمت تبدیل شده، اما در نمونه دوم به تغییر جهت قیمت سهام در پیش‌بینی قیمت توجه شده است.



شکل ۱. مقایسه دو پیش‌بینی و سود کسب شده با معاملات انجام گرفته در ۱۴ روز

پیش‌بینی دقیق قیمت، توانایی سرمایه‌گذاران برای ایجاد یک پرتفوی مناسب از انواع سهام و سودآوری آن را افزایش می‌دهد. روش‌های مختلفی برای تشکیل پرتفویو مانند برنامه‌ریزی تصادفی چندهدفه (شریفی سلیم، مؤمنی، مدرس یزدی و راعی، ۱۳۹۴) و بهینه‌سازی آن وجود دارد (علی‌پور جورشری، یاکیده و محفوظی، ۱۳۹۶؛ گودرزی، یاکیده و محفوظی، ۱۳۹۵). همچنین، استراتژی‌های متفاوتی برای حفاظت از ارزش پرتفویو مطرح شده که هر یک پشتوانه علمی و عملی خاص خود را دارد و بسته به نوع بازار بورس و شرایط آن، بهتر عمل می‌کند. شش استراتژی مطرح در این زمینه عبارت‌اند از:

۱. استراتژی توقف ضرر^۱: فروش سهام خریداری‌شده به شرطی که قیمت از حد معینی پایین‌تر برود.
 ۲. اختیار معامله فروش: با پرداخت حق‌الزحمه (قیمت) خریداری می‌شود و فروشنده تعهد می‌کند که سهام پایه را به قیمتی معین در طول دوره مشخصی خریداری کند.
 ۳. متنوع‌سازی^۲: ترکیبی از دارایی‌ها (مانند سهام، پول نقد، اوراق قرضه و کالا) به گونه‌ای انتخاب می‌شود که از صنایع متعدد و از مناطق گسترده جغرافیایی باشد تا ریسک آن کنترل شود. میزان حفاظت از سرمایه‌گذاری (برای مثال ۶۰ درصد سهام، ۴۰ درصد اوراق قرضه) بر اساس سطح ریسک مورد قبول سرمایه‌گذار تعیین می‌شود.
 ۴. متعادل‌سازی^۳: این استراتژی شامل خرید و فروش دوره‌ای دارایی‌ها به منظور ایجاد تعادل مجدد در پرتفویو می‌شود.
 ۵. دارایی‌های ناهمبسته^۴: پرتفویویی که تعداد زیادی سهم مختلف دارد، می‌تواند کل ریسک غیرسیستماتیک را حذف کند.
 ۶. سود نقدی^۵: سرمایه‌گذاری در سهم‌هایی که سود نقدی پرداخت می‌کنند، کمترین کاری است که برای حفاظت از ارزش پرتفویو می‌توان انجام داد.
- در مدل پیشنهاد شده، با ساختار دوبخشی به تغییر جهت قیمت سهام توجه شده است. در بخش اول، جهت بعدی حرکت قیمت سهام (افزایش یا کاهش) پیش‌بینی شده و برای پیش‌بینی قیمت در مرحله دوم از نتیجه بخش اول استفاده می‌شود. در این مدل از یادگیری جمعی با استفاده از مدل‌های پایه هوشمند در هر دو بخش بهره‌برده شده تا بازده نتایج پیش‌بینی به حداکثر برسد.

روش‌شناسی پژوهش

مطالعات متعدد در خصوص به‌کارگیری روش‌های آموزش نشان می‌دهد الگوریتم آموزشی مشخصی وجود ندارد که بتواند برای تمام پیش‌بینی‌ها بهترین و دقیق‌ترین باشد. برای غلبه بر این مشکل، الگوریتم‌های یادگیری جمعی بسیاری با انگیزه کاهش خطا توسعه یافته‌اند. فرض مبنایی این متدولوژی، آن است که در حالت جمعی احتمال خطای پیش‌بینی در یک نمونه جدید، خیلی کمتر از حالت پیش‌بینی با یک مدل منفرد است. در مقایسه با روش‌های یادگیری ماشینی معمول

1. Stop Loss
2. Diversification
3. Rebalancing
4. Non-correlating
5. Dividen

که سعی در یادگیری یک فرضیه از داده‌های آموزش دارند، در روش‌های یادگیری جمعی چندین یادگیرنده برای رسیدن به بیشترین دقت ممکن آموزش می‌بینند و برای ساخت مجموعه‌ای از فرضیه‌ها و ترکیب آنها برای استفاده تلاش می‌کنند (وانگ، هاو، ما و جیانگ، ۲۰۱۱). یادگیرنده‌هایی که به وسیله یک روش یادگیری جمعی ترکیب شده باشند را معمولاً یادگیرنده‌های پایه می‌نامند و ثابت شده است مدل‌های یادگیری جمعی که ترکیبی از یادگیرنده‌های پایه هستند، نسبت به روش‌های منفرد دقت بهتری ارائه می‌دهند (دیتیریش، ۲۰۰۰).

قاعده کلی در سیستم‌های یادگیری جمعی این است که نتایج هر مدل تا حد امکان به‌طور مناسبی از یکدیگر متفاوت باشند. این گوناگونی می‌تواند از راه‌های مختلفی حاصل شود. چهار روش پیشنهادی (کوبیلاس دلاوگا، بلانکو الیور، پینو مجیس و لارا رویو، ۲۰۱۳) برای گوناگونی عبارت‌اند از:

- استفاده از مجموعه داده‌های آموزش متفاوت برای آموزش هر مدل؛
- تغییر در پارامترهای مدل‌ها؛
- استفاده از ویژگی‌های مختلف؛
- استفاده از مدل‌های بی‌ثبات^۱.

یکی از ساده‌ترین الگوریتم‌های یادگیری جمعی، بگینگ^۲ نام دارد که برای بهبود کارایی مدل‌های پیش‌بینی ارائه شده و استراتژی ترکیبی یادگیرنده‌های پایه در آن، رأی اکثریت است (بریمن، ۱۹۹۶). تنوع در بگینگ با استفاده از نمونه‌های خود راه‌انداز^۳ که به‌طور تصادفی و با جایگزینی، از کل مجموعه داده آموزشی انتخاب می‌شوند، ایجاد می‌شود. هر خود راه‌انداز، برای آموزش یک یادگیرنده از نوع یکسان استفاده می‌شود. به‌کار بردن بگینگ هنگام استفاده از روش‌های یادگیری ناپایدار مانند درخت‌ها و شبکه‌های عصبی، بسیار کارا و اثربخش است؛ زیرا تغییرات کوچکی در داده می‌تواند باعث تغییرات بزرگی در مقادیر پیش‌بینی شود (کوبیلاس دلاوگا، بلانکو الیور، پینو مجیس و لارا رویو، ۲۰۱۳).

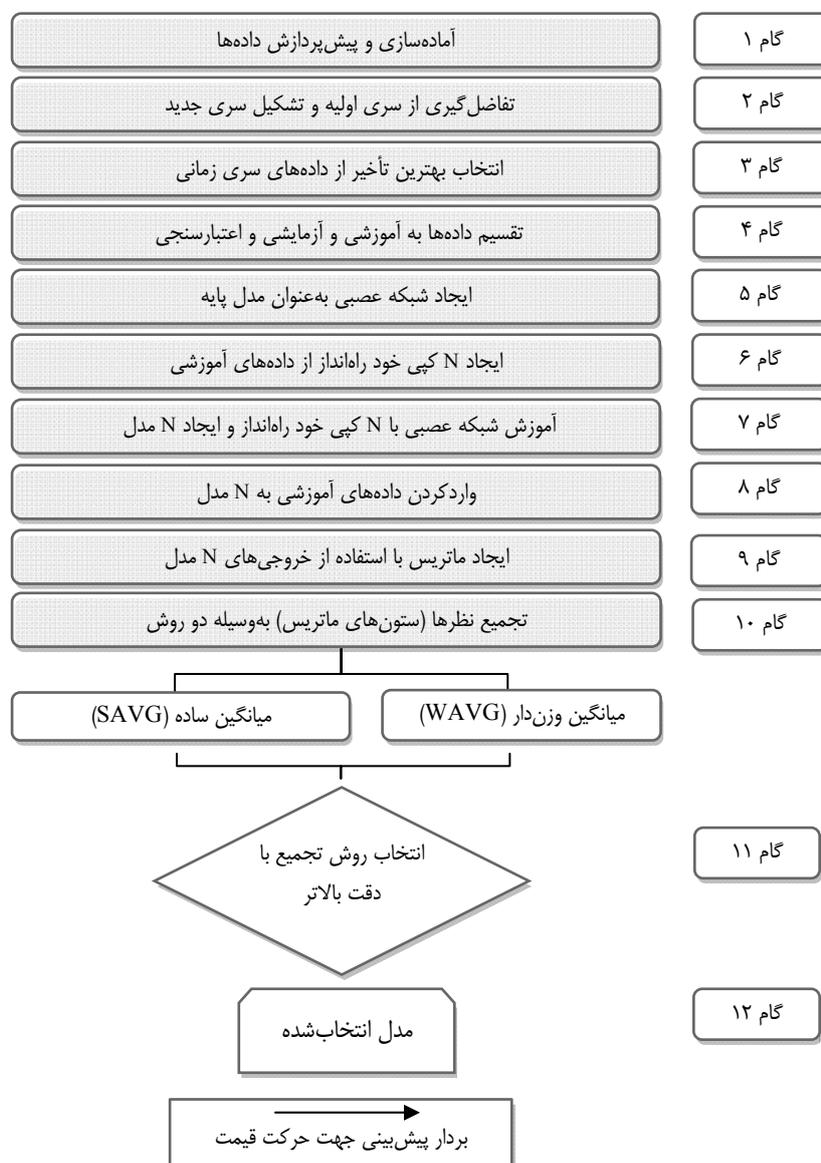
بعد از آموزش یادگیرنده‌های مختلف با روش بگینگ، برای رسیدن به جواب نهایی پیش‌بینی، باید جواب‌های به‌دست آمده از همه یادگیرنده‌ها برای یک نمونه خاص با هم ترکیب شوند. انواع روش‌های مختلف از جمله میانگین و میانگین وزن‌دار در این زمینه استفاده شده است (خوزه و وینکلر ۲۰۰۸؛ اندراوس، آتیا و الشیشینی، ۲۰۱۱). در این مقاله دو روش میانگین ساده (SAV)^۴ که وزن همه یادگیرنده‌ها را در تولید جواب نهایی برای پیش‌بینی یک نمونه خاص، یکسان نشان می‌دهد و روش میانگین وزن‌دار (WAV)^۵ که نقش هر یادگیرنده در پیش‌بینی نهایی بر اساس دقت آن در مرحله آموزش و در مقایسه با سایر یادگیرنده‌ها تعیین می‌شود، استفاده شده است.

مدل پیشنهادی

با توجه به چالش‌ها و مشکلات مطرح شده، یک روش جدید پیش‌بینی قیمت سهام با رویکرد توجه به جهت تغییر قیمت معرفی می‌شود. مدل پیشنهاد شده شامل دو مرحله وابسته به هم است. ابتدا جهت تغییر قیمت پیش‌بینی می‌شود و

1. Unstable
 2. Bagging (bootstrap aggregating)
 3. Bootstrapped Replicas
 4. Simple Average
 5. Weighted Average

به‌عنوان یک ویژگی جدید به سایر ویژگی‌ها اضافه‌شده و با استفاده از این مجموعه داده جدید، قیمت در زمان بعدی پیش‌بینی می‌شود. در مرحله اول برای افزایش دقت رده‌بندی (پیش‌بینی تغییرات جهت قیمت) تا بیشترین مقدار ممکن و در مرحله دوم برای افزایش دقت رگرسیون (پیش‌بینی قیمت) در مدل پیشنهاد شده از روش بگینگ استفاده شده است.



شکل ۲. فرایند اجرای مرحله اول مدل

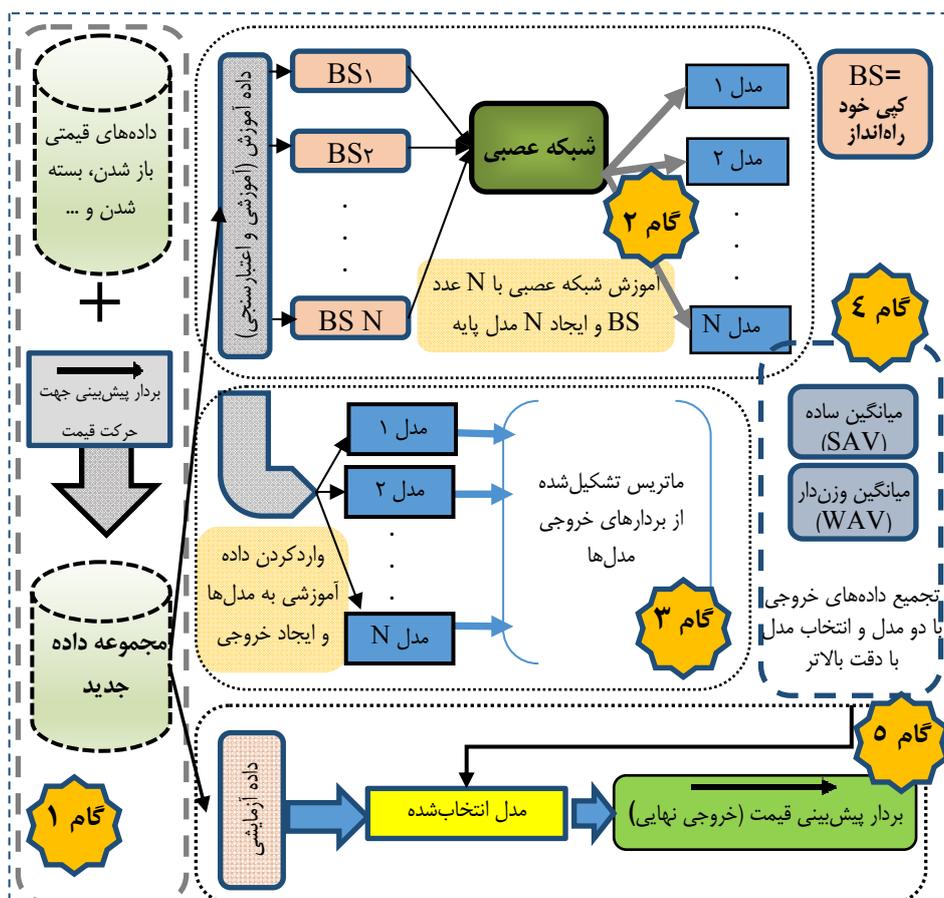
مرحله اول (استخراج جهت تغییر قیمت)

اغلب سری‌های زمانی داده‌های سهام در بورس، ناپایدار بوده و روندی دارند که این مسئله موجب کاهش دقت در پیش‌بینی می‌شود. بنابراین لازم است داده‌ها در حد ممکن ایستا شوند. ایستایی در میانگین سری زمانی از طریق تفاضل‌گیری و ایستایی در واریانس آن با استفاده از تبدیل لگاریتم، انجام می‌شود. انجام این دو تکنیک موجب می‌شود که دانش موجود در داده‌ها با دقت بیشتری کشف شود (کوگلی و ناسون، ۱۹۹۵). تفاضل‌گیری موجب می‌شود یک سری

زمانی جدید تولید شود که اجزای آن تغییر قیمت‌های سری زمانی اولیه‌اند و با پیش‌بینی اجزای بعدی آن، هدف این بخش از مدل که پیش‌بینی تغییر جهت بعدی قیمت است تحقق می‌یابد. در این مرحله جزء n ام سری، همراه با k تأخیر قبلی به‌عنوان ورودی به مدل وارد شده و جزء $n + 1$ ام پیش‌بینی می‌شود. فرایند انجام این کار در شکل ۲ نمایش داده شده است.

مرحله دوم (استخراج قیمت)

با اتمام مرحله نخست خروجی، جهت تغییرات قیمت در بازار سهام (رو به بالا یا رو به پایین بودن) مشخص می‌شود. با اضافه شدن این خروجی (ویژگی جدید) به سایر متغیرهای قیمتی، مدلی متشکل از همه داده‌ها ساخته می‌شود و با آزمایش تأخیرهای مختلف، بهترین ترکیب از تأخیرها انتخاب شده و به‌عنوان ورودی مدل بخش دوم استفاده خواهد شد. روش‌های استفاده‌شده در این بخش از لحاظ مفهومی تا حدی مشابه بخش نخست است، اما در اجرا تفاوت‌هایی دارد؛ از جمله اینکه معیارهای ارزیابی در مدل‌های پایه و روش‌های تجمیع در این بخش، به جای ارزیابی صحت نتایج در پیش‌بینی درست جهت، به ارزیابی دقت در قیمت پیش‌بینی‌شده با معیار MAPE تغییر می‌کند. مراحل اجرای فرایند مرحله دوم مدل پیشنهاد شده در شکل ۳ مشاهده می‌شود.



شکل ۳. فرایند اجرای مرحله دوم مدل پیشنهادی

یافته‌های پژوهش

در این بخش عملکرد مدل پیشنهاد شده با استفاده از داده‌های مختلف ارزیابی می‌شود و شامل زیربخش‌های معرفی مجموعه داده‌ها، معیارهای ارزیابی، پیاده‌سازی مدل دومرحله‌ای (شامل آموزش و آزمایش مدل) و در نهایت، مقایسه نتایج به دست آمده از مدل پیشنهادی با نتیجه سایر مقاله‌هاست.

مجموعه داده

برای مقایسه عملکرد مدل پیشنهاد شده، آن را روی داده‌هایی که در مقاله‌های اصفهانی‌پور و آقامیری (۲۰۱۰) و اسدی و همکاران (۲۰۱۲) برای پیش‌بینی قیمت سهام استفاده شده است، آزمایش می‌کنیم. مجموعه داده استفاده شده در این مقاله چهار شاخص کل، صنعت، مالی و ۵۰ شرکت برتر بورس تهران هستند. اطلاعات مربوط به داده‌ها و بازه زمانی آنها در جدول ۲ معرفی شده‌اند.

جدول ۲. شرح شاخص‌های سهام

نام شاخص بورس	از	تا	متوسط	انحراف معیار
شاخص کل بورس تهران	۸۵/۱/۲۱	۸۷/۱۱/۹	۹۹۹۱/۶۳۱	۹۷۳/۶۳
شاخص ۵۰ شرکت برتر	۸۵/۱/۲۱	۸۷/۱۱/۹	۱۶۵۶۲/۴۹	۳۷۱۵/۶
شاخص صنعت	۸۵/۱/۲۱	۸۷/۱۱/۹	۷۸۶۹/۹۳۷	۸۳۴/۶۹
شاخص مالی	۸۵/۱/۲۱	۸۷/۱۱/۹	۲۰۵۸۴/۰۷	۲۳۸۳/۵۳

معیارهای ارزیابی

با توجه به رویکرد مقاله برای بهبود هم‌زمان پیش‌بینی قیمت و پیش‌بینی جهت تغییرات آن، معیارهای ارزیابی نتایج نیز باید این دو مفهوم را پشتیبانی کنند. نخستین معیار که استفاده از آن بسیار رایج است و میزان نزدیک بودن قیمت پیش‌بینی شده به قیمت واقعی را نشان می‌دهد، MAPE است. در این معیار قدر مطلق اختلاف بین مقدار واقعی و مقدار پیش‌بینی شده بر مقدار واقعی تقسیم می‌شود و با تقسیم بر تعداد داده‌های موجود در مسئله، میانگین آن برحسب درصد بیان می‌شود. در رابطه ۱، y_i معرف مقدار واقعی، p_i مقدار پیش‌بینی شده و N تعداد داده‌هاست.

$$MAPE = 100 \times \frac{1}{N} \sum \frac{y_i - p_i}{y_i} \quad \text{رابطه ۱}$$

دقت مدل در پیش‌بینی تغییر جهت قیمت، همراه با پیش‌بینی صحیح قیمت، نقش مهمی در سودآوری دارد. معیار $POCID$ صحت پیش‌بینی تغییر جهت قیمت را ارزیابی می‌کند. این معیار عددی بین ۰ تا ۱۰۰ را به دست می‌آورد که هر چه به ۱۰۰ نزدیک‌تر باشد، نشان‌دهنده دقت بهتر پیش‌بینی است (فریرا، واسکونسولوس و ادیوتاتو، ۲۰۰۸).

$$POICD = 100 \times \frac{1}{N} \sum_{i=0}^n D_i \quad \text{رابطه ۲}$$

$$D_i = \begin{cases} 1, & \text{if } (y_i - y_{i-1})(p_i - p_{i-1}) > 0 \\ 0, & \text{otherwise} \end{cases} \quad \text{رابطه ۳}$$

معیار سوم U of Tail عملکرد مدل را با مدل گام تصادفی مقایسه می‌کند. در صورتی که مقدار به‌دست آمده از این معیار برابر ۱ باشد، نتیجه مدل پیش‌بینی برابر عملکرد مدل گام تصادفی خواهد بود. اگر عدد به‌دست آمده کمتر از ۱ باشد، عملکرد مدل پیشنهاد شده بهتر است و اگر بیش از ۱ باشد، مدل پیشنهاد شده در مقایسه با مدل گام تصادفی عملکرد ضعیف‌تری دارد (راوی، پردیکومار و دب، ۲۰۱۷)

$$U \text{ of Tail} = \frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (y_i - y_{i+1})^2} \quad \text{رابطه ۴}$$

معیار چهارم یا ARV^۱، نتایج را با میانگین سری زمانی مقایسه می‌کند. برابر بودن مقدار معیار یاد شده با ۱ به این معناست که اگر به‌جای همه اعداد پیش‌بینی شده توسط مدل، میانگین اعداد موجود در سری زمانی را قرار دهیم، دقت پیش‌بینی تغییر نمی‌کند. عدد به‌دست آمده از این معیار هرچه کوچک‌تر از ۱ و به ۰ نزدیک باشد، نشان‌دهنده دقت بیشتر پیش‌بینی در مدل پیشنهاد شده است (فریرا، واسکونسوس و ادیوتاتو، ۲۰۰۸).

$$ARV = \frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (\bar{y} - p_i)^2} \quad \text{رابطه ۵}$$

پیاده‌سازی مدل دومرحله‌ای

در پژوهش‌های پیشین برای ورودی مدل‌های پیش‌بینی‌کننده قیمت سهام، از متغیرهای قیمتی، تکنیکالی، اساسی و اقتصاد کلان استفاده شده است که می‌توان آنها را در گروه‌های مختلفی دسته‌بندی کرد (دی‌الیویرا، نوبره و زاراته، ۲۰۱۳). یکی از دسته‌بندی‌های رایج برای متغیرهای ورودی به مدل‌های پیش‌بینی بازار سهام، آنها را به دو نوع تقسیم می‌کند. متغیرهایی مانند باز شدن، بسته شدن، پایین‌ترین و بالاترین قیمت و همچنین حجم و تعداد معاملات در یک بازه زمانی، نوع اول متغیرهای قیمت‌اند. نوع دوم که متغیرهای تکنیکال نامیده می‌شوند با استفاده از فرمول‌های مختلف از این متغیرهای قیمتی به‌دست می‌آیند. برخی محققان از متغیرهای قیمت (حسن، ۲۰۰۹) و برخی دیگر از متغیرهای تکنیکال (تیکنور، ۲۰۱۳) استفاده کرده‌اند. در مدل پیشنهاد شده این مقاله، از متغیرهای قیمت استفاده شده است.

هر سری زمانی در جدول ۱ شامل ۶۲۰ داده است که به دو بخش آموزشی و آزمایشی دسته‌بندی شده و ۵۰۰ داده (۸۰ درصد) برای آموزش و ۱۲۰ داده (۲۰ درصد) برای آزمایش استفاده می‌شود. در مقاله‌هایی که نتایج این مدل با آنها مقایسه می‌شود نیز، داده‌ها به همین صورت به آموزش و آزمایش، دسته‌بندی شده‌اند (اسدی و همکاران، ۲۰۱۲).

خروجی نهایی مدل پیشنهاد شده، پیش‌بینی قیمت در بازه بعدی با توجه به جهت تغییرات قیمت است. در مرحله نخست که مدل وظیفه مشخص کردن جهت تغییرات قیمت و پیش‌بینی آن برای زمان بعدی را بر عهده دارد، داده‌های آزمایشی (۲۰ درصد داده‌ها) جدا شدند و داده‌های آموزشی (شامل داده‌های آموزش و اعتبارسنجی) همراه با تأخیرهای مناسب، یادگیرندگان پایه را آموزش خواهند داد. داده‌ها برای ورود به مدل در مرحله اول، تفاضل‌گیری شده و داده‌های جدید، تغییر قیمت‌ها در دو زمان متوالی است.

در مدل پیشنهاد شده، مدل‌های پایه، شبکه‌های عصبی هستند که پارامترهای مختلفی بر عملکرد و دقت آنها تأثیر می‌گذارند. علاوه بر این، پارامترهای دیگری بر عملکرد مدل یادگیری جمعی مؤثرند که مجموعه‌ای از آنها در جدول ۳ مشاهده می‌شود.

جدول ۳. پارامترهای مؤثر بر نتایج مدل

ردیف	پارامتر	ردیف	پارامتر
۱	نوع ساختار شبکه عصبی	۸	تعداد لایه‌های پنهان
۲	الگوریتم آموزشی	۹	تابع تحریک
۳	الگوریتم خطایابی	۱۰	درصد داده‌های آموزش
۴	تابع بهینه‌سازی	۱۱	درصد داده‌های اعتبارسنجی
۵	نرخ یادگیری	۱۲	تعداد تأخیرهای استفاده شده
۶	استفاده از تبدیل لگاریتم	۱۳	تعداد نمونه‌ها
۷	درصد استفاده از داده‌های هر نمونه	۱۴	روش تجمیع نظرات

همان‌گونه که قبلاً در بخش روش‌شناسی پژوهش این مقاله توضیح داده شد، در مدل‌های یادگیری جمعی، دقت بیشتر از طریق تنوع‌بخشی در نتیجه مدل‌های پایه حاصل می‌شود و تنظیم پارامترهای مدل جمعی نسبت به مدل‌های پایه که شبکه‌های عصبی هستند، اهمیت بیشتری دارند. استفاده از تبدیل لگاریتم، اعمال تأخیرهای مختلف روی داده‌ها، تغییر در اندازه دسته‌بندی بین داده‌های آموزش و اعتبارسنجی، تعداد نمونه‌ها و درصد استفاده از داده‌های هر نمونه و در نهایت، روش تجمیع نظر مدل‌های پایه، تنظیماتی است که روی داده‌های ورودی و پارامترهای مدل می‌توان انجام داد. با توجه به تعدد پارامترهای مدل پیشنهاد شده و مقادیر مختلفی که می‌توان در آنها قرار داد، اگر تعداد آزمایش‌ها با روش فاکتوریل محاسبه شود، به دلیل داشتن متغیرهای زیاد، تعداد آزمایش‌ها بسیار زیاد خواهد شد و این مسئله از نظر زمان و هزینه به صرفه نیست. به کمک روش تاگوچی این امکان وجود دارد که با تعداد آزمایش بسیار کمتر، ترکیب‌های مختلفی از سطوح پارامترها را برای دستیابی به نتیجه، ارزیابی کرد. در مرحله اول پارامترها مشخص شده و برای هر یک با توجه به هدف، چند حالت در نظر گرفته می‌شود. این روش با توجه به تعداد پارامترهای مؤثر و تعداد سطوح، تعداد محدودی آزمایش که در آن سطح هر پارامتر مشخص شده است را پیشنهاد می‌دهد. نتایج این تعداد محدود آزمایش، به حالتی که همه آزمایش‌ها برای همه پارامترها در همه سطوح انجام شود، بسیار نزدیک است. برای پیاده‌سازی روش تاگوچی در این مقاله، از نرم‌افزارهای آماری مینی‌تب^۱ استفاده شده است.

نتایج ارزیابی برای خروجی داده‌های آموزشی مرحله اول که بالاترین دقت را داشته‌اند، همراه با پارامترهایی که داده و مدل‌ها با آن تنظیم شده‌اند، در جدول ۴ درج شده است.

همان‌گونه که در جدول ۴ مشاهده می‌شود، برای داده شاخص کل بورس تهران بهترین دقت موقعیتی است که تبدیل لگاریتم برای داده‌ها انجام شده و از هفت تأخیر استفاده شود، علاوه بر این ۳ درصد داده‌های آموزشی برای اعتبارسنجی

و ۱۰۰ درصد داده‌های هر بوت‌استرپ در آموزش مدل پایه استفاده شوند. تعداد نمونه‌ها در این نتیجه ۲۰۰ بوده و تکنیکی که با آن روش‌های پایه تجمیع شده‌اند، میانگین وزن دار است. با توجه به این تنظیمات برای داده بورس تهران ۷۳/۷ درصد از تغییر جهت‌ها در داده‌های آموزشی صحیح پیش‌بینی شده است.

بردار خروجی پیش‌بینی به‌دست آمده از بخش نخست، به سایر متغیرهای قیمتی اضافه‌شده و داده‌های ورودی به بخش دوم مدل را تشکیل می‌دهند. در این بخش نیز مدل‌سازی با تنظیمات پیشنهاد شده روش تاگوچی انجام می‌شود تا بهترین نتیجه به‌دست آید. تغییر تنظیمات، شامل انتخاب تأخیرهای مختلف برای داده‌ها و همچنین تغییر تعداد نرون‌ها برای ساختن شبکه عصبی، به‌علاوه سایر مواردی است که در مرحله اول استفاده شده است.

جدول ۴. نتایج مرحله اول اجرای مدل

مجموعه داده	تنظیمات	شاخص مالی	شاخص صنعت	شاخص ۵۰ شرکت برتر	شاخص کل
استفاده از تبدیل لگاریتم	✓	✓	-	✓	✓
تأخیر استفاده‌شده	۵	۷	۷	۹	۷
درصد داده‌های اعتبار سنجی	۵٪	۳٪	۳٪	۲٪	۳٪
درصد استفاده از داده‌های هر نمونه	۹۵٪	۹۵٪	۹۵٪	۹۵٪	۱۰۰٪
تعداد نمونه‌ها	۳۰۰	۳۰۰	۳۰۰	۳۰۰	۲۰۰
روش تجمیع نظرها	WAV	WAV	WAV	SAV	WAV
درصد پیش‌بینی درست جهت	۷۳/۱	۷۶/۸	۷۵/۶	۷۳/۷	۷۳/۷

بعد از هر بار آموزش مدل‌های منفرد و تجمیع آن، ترکیبی که بهترین نتیجه ارزیابی در داده‌های آموزشی را داشته باشد، انتخاب می‌شود؛ سپس داده‌های آزمایشی به مدل وارد می‌شوند و مدل با آنها ارزیابی می‌شود. نتیجه ارزیابی برای داده‌های آزمایشی، همراه با تنظیماتی که این نتایج را ایجاد کرده‌اند، در جدول ۵ مشاهده می‌شود.

جدول ۵. نتایج مرحله دوم اجرای مدل

مجموعه داده	تنظیم‌ها	شاخص مالی	شاخص صنعت	شاخص ۵۰ شرکت برتر	شاخص کل
تأخیر استفاده‌شده	۲	۲	۳	۳	۲
درصد داده‌های اعتبار سنجی	۰٪	۲٪	۲٪	۳٪	۳٪
تعداد نرون‌ها در شبکه عصبی پایه	۷	۵	۵	۷	۶
درصد استفاده از داده‌های هر نمونه	۱۰۰٪	۹۵٪	۹۵٪	۱۰۰٪	۹۵٪
تعداد نمونه‌ها	۱۰۰	۳۰۰	۳۰۰	۳۰۰	۲۰۰
روش تجمیع نظرها	SAV	WAV	WAV	WAV	WAV
MAPE	۰/۳۱	۰/۲۹	۰/۳۲	۰/۳۷	۰/۳۷
POCID	۶۵/۱۸	۷۴/۳	۶۳/۴۹	۶۰/۲	۶۰/۲
U of Theil	۰/۶۷	۰/۵۹	۰/۴۸	۰/۵۵	۰/۵۵
ARV	۰/۰۱۳	۰/۰۴	۰/۰۸۶	۰/۰۰۳	۰/۰۰۳

همان گونه در جدول ۵ مشاهده می شود، برای داده شاخص کل بهترین دقت موقعیتی است که از ۲ تأخیر استفاده شود و ۳ درصد داده های آموزشی برای اعتبارسنجی در نظر گرفته شده باشد. همچنین ۶ نرون در مدل های پایه و ۹۵ درصد داده های هر بوت استراپ در مرحله آموزش استفاده شوند. تعداد نمونه ها برای این نتیجه ۲۰۰ عدد و تکنیکی که با آن روش های پایه تجمیع شده اند، میانگین وزن دار است.

مقایسه مدل پیشنهاد شده با روش های پیشین

در این مقاله برای مقایسه نتایج، از داده های مشابه مقاله های معتبر در حوزه پیش بینی قیمت سهام (اسدی و همکاران، ۲۰۱۲ و اصفهانی پور و آقامیری، ۲۰۱۰) استفاده شده است. در جدول ۶ عدد به دست آمده از مدل پیشنهاد شده برای معیار MAPE، همراه با عدد به دست آمده از نتیجه کار سایر محققان و همچنین درصد بهبود این معیار توسط مدل پیشنهاد شده مشاهده می شود و نتایج گویای برتری مدل پیشنهاد شده نسبت به سایر مدل هاست.

جدول ۶. مقایسه نتایج مدل پیشنهاد شده با روش های پیشین

شاخص کل		شاخص ۵۰ شرکت برتر		شاخص صنعت		شاخص مالی		مجموعه داده
بهبود	معیار MAPE	بهبود	معیار MAPE	بهبود	معیار MAPE	بهبود	معیار MAPE	روش
%۸۵	۲/۴	%۸۰	۱/۸۵	%۸۶	۲/۰۲	%۷۰	۱/۰۳	خوشه بندی فازی با مدل فازی سوگنو
%۶۲	۰/۹۷	%۷۴	۱/۴	%۸۳	۱/۷۳	%۶۷	۰/۹۴	شبکه عصبی با آموزش پس انتشار
%۴۲	۰/۶۴	%۶۷	۱/۱۲	%۷۸	۱/۳	%۶۱	۰/۷۹	پیش پردازش تکاملی و شبکه عصبی
%۳۹	۰/۶۱	%۵۶	۰/۸۳	%۷۱	۰/۹۸	%۵۵	۰/۶۹	پیش پردازش تکاملی و شبکه عصبی با آموزش پس انتشار
%۲۶	۰/۵	%۵۲	۰/۷۶	%۶۸	۰/۸۹	%۵۳	۰/۷۷	شبکه عصبی با بهینه سازی آموزش با الگوریتم ژنتیک
	۰/۳۷		۰/۳۷		۰/۲۹		۰/۳۱	مدل پیشنهاد این مقاله

در مدل پیشنهاد شده این مقاله، همزمان معیارهای پیش بینی قیمت و جهت حرکت بازار در نظر گرفته شده است. نتایج با یافته های پژوهش (اسدی، هداوندی، مهمانپذیر و نخستین، ۲۰۱۲) که علاوه بر معیار MAPE از معیار POICD برای پیش بینی تغییرات جهت استفاده کرده، مقایسه می شود. این نتایج نشان می دهد که مدل پیشنهاد شده در پژوهش حاضر، نسبت به مدلی که در مقاله اسدی ارائه شده، دقت بیشتری دارد (جدول ۷).

جدول ۷. مقایسه نتایج مدل پیشنهاد شده با مدل ارائه شده در مقاله اسدی (۲۰۱۲) با ۴ معیار ارزیابی

ARV	U of Theil	بهبود	معیار POICD		بهبود	معیار MAPE		شاخص
			مدل پیشنهادی	مقاله اسدی		مدل پیشنهادی	مقاله اسدی	
۰/۰۱۳	۰/۶۷۲	%۴	۶۹/۱	۶۶/۶	%۵۳	۰/۳۱	۰/۶۶	شاخص مالی
۰/۰۴	۰/۵۸۸	%۴	۷۴/۳	۷۱/۵	%۶۸	۰/۲۹	۰/۸۹	شاخص صنعت
۰/۰۸۶	۰/۴۸۳	%۲	۵۹/۵	۵۷/۵	%۵۲	۰/۳۷	۰/۷۶	شاخص ۵۰ شرکت برتر
۰/۰۰۳	۰/۵۵۲	%۱	۶۱/۲	۶۰	%۲۶	۰/۳۷	۰/۵۰	شاخص کل

نتایج ارزیابی U of Theil نشان می‌دهد مدل پیشنهاد شده در همه موارد بهتر از مدل گام تصادفی عمل می‌کند و در خصوص معیار ARV نیز، نتایج فاصله زیادی با ۱ دارند که بنا بر تعریف این معیار، نتیجه مطلوب است. مدل پیشنهاد شده از نظر معیارهای MAPE و POICD در همه موارد، دارای دقت پیش‌بینی بیشتری است.

بحث و نتیجه‌گیری

پیش‌بینی قیمت سهام با دقت زیاد برای معامله در این بازار بسیار مهم است. برخی از تئوری‌های مالی کلاسیک، بازار را پیش‌بینی‌ناپذیر می‌دانند. نتیجه استفاده از روش‌های مبتنی بر هوش مصنوعی، نشان داده است که پیش‌بینی بازار سهام با وجود ماهیت نوسانی و ناپایدار آن، امکان‌پذیر است. در این مقاله با دسته‌بندی روش‌های هوشمند پیش‌بینی بازار سهام و بررسی مزایا و معایب آنها، الگوریتم‌های یادگیری جمعی، مناسب‌ترین روش برای کاربرد پیش‌بینی بازار سهام تشخیص داده شد. همچنین با ارائه نمونه‌هایی، نقش پیش‌بینی صحیح جهت قیمت در پیش‌بینی قیمت سهام و اهمیت آن در سودآوری معاملات بررسی گردید. پس از بررسی مدل‌ها مشخص شد که در بیشتر آنها قیمت بدون در نظر گرفتن جهت حرکت قیمت پیش‌بینی شده و این موضوع به غیرعملی شدن نتایج انجامیده است. برای غلبه بر چالش‌های بیان شده، در این مقاله با استفاده از یک مدل یادگیری جمعی و به‌کارگیری مدل‌های پایه هوشمند، تلاش شد که بهبود نتایج پیش‌بینی به حداکثر رسانده شود. همچنین برای در نظر گرفتن جهت تغییر قیمت در پیش‌بینی قیمت، از ساختار دویبخشی استفاده شده است که در بخش اول، تغییر جهت بعدی حرکت قیمت سهام (افزایش یا کاهش) را پیش‌بینی کرده و برای پیش‌بینی قیمت در مرحله دوم، از همان نتیجه استفاده می‌کند. با توجه به رویکرد مقاله برای بهبود هم‌زمان پیش‌بینی جهت تغییرات قیمت و همچنین قیمت، از معیارهای ارزیابی که بتواند دقت هر دو مورد را ارزیابی کند، بهره برده شده است. علاوه بر آن، نتایج با معیارهایی که نشان‌دهنده عدم تصادفی بودن است، ارزیابی شدند و مشخص شد که پیش‌بینی‌ها تصادفی نیستند. نتایج پیاده‌سازی مدل پیشنهاد شده روی چند مجموعه داده نشان داد که مدل پیشنهاد شده در مقایسه با سایر مدل‌ها، عملکرد مطلوب‌تری دارد و می‌تواند به‌عنوان یک سیستم پشتیبان از تصمیم‌مطمئن در معاملات واقعی بازار سهام استفاده شود. در این رویکرد، مدل برای هر مجموعه داده با تنظیمات مختلف به اجرا درآمده و بهترین تنظیمات با توجه به معیارهای ارزیابی برای هر مجموعه داده انتخاب می‌شود. مدل پیشنهاد شده برای داده‌های دیگر نیز کاربرد دارد و با اجرای آن، تنظیمات مناسب برای پیش‌بینی در هر مجموعه داده به دست می‌آید. برای تحقیقات آینده، موضوعات زیر پیشنهاد می‌شود:

۱. از داده‌های تکنیکالی برای متغیرهای ورودی به مدل استفاده شود؛
۲. از روش‌های متاهوریستیک برای تجمیع نتایج مدل‌های پایه استفاده شود؛
۳. نتیجه مدل‌ها به صورت عملی و با توجه به هزینه معاملات شبیه‌سازی شوند.

منابع

سعیدی، حسین؛ محمدی، شاپور (۱۳۹۰). پیش‌بینی نوسانات بازده بازار با استفاده از مدل‌های ترکیبی گارچ شبکه عصبی. فصلنامه بورس اوراق بهادار، ۴(۱۶)، ۱۵۳-۱۷۴.

- شریفی سلیم، علیرضا؛ مؤمنی، منصور؛ مدرس یزدی، محمد؛ راعی، رضا (۱۳۹۴). برنامه‌ریزی تصادفی چندهدفه برای انتخاب سبد سهام. *نشریه مدیریت صنعتی*، ۷(۳)، ۴۸۹-۵۱۰.
- علی‌پور جورشری، ارمغان؛ یاکیده، کیخسرو؛ محفوظی، غلامرضا (۱۳۹۶). بهینه‌سازی سبد سهام با حداقل میانگین انحرافات مطلق کارایی‌های متقاطع. *نشریه مدیریت صنعتی*، ۹(۳)، ۴۷۵-۴۹۶.
- گودرزی، مهشید؛ یاکیده، کیخسرو؛ محفوظی، غلامرضا (۱۳۹۵). بهینه‌سازی سبد سهام با تلفیق کارایی متقاطع و نظریه بازی‌ها. *نشریه مدیریت صنعتی*، ۴(۸)، ۶۸۵-۷۰۶.
- منجمی، سید امیرحسین؛ ابزری، مهدی؛ رعیتی شوازی، علیرضا (۱۳۸۸). پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک و مقایسه آن با شبکه عصبی مصنوعی. *اقتصاد مقداری*، ۶(۳)، ۲۶-۱.
- نیکبخت، محمد رضا؛ شریفی، مریم (۱۳۸۹). پیش‌بینی ورشکستگی مالی شرکت‌های بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی. *نشریه مدیریت صنعتی*، ۲(۴)، ۱۶۳-۱۸۰.

References

- Adebiyi, A. A., Adewumi, A.O., & Ayo, C. K. (2014). Comparison of ARIMA and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*, 2014, 1-7.
- Adhikari, R. (2015). A neural network based linear ensemble framework for time series forecasting. *Neurocomputing*, 157(25), 231-242.
- Alipour, A., Yakideh, K., & Mahfoozi, Gh. (2017). Portfolio Optimization with Minimum Average Absolute Deviations of Cross-efficiency. *Industrial Management Journal*, 9(3), 475-496. (in Persian)
- Andrawis, R. R., Atiya, A. F., & El-Shishiny, H. (2011). Forecast combinations of computational intelligence and linear models for the NN5 time series forecasting competition. *International journal of forecasting*, 27(3), 672-688.
- Asadi, Sh., Hadavandi, E., Mehmanpazir, F., & Nakhostin, M.M. (2012). Hybridization of evolutionary Levenberg-Marquardt neural networks and data pre-processing for stock market prediction. *Knowledge-Based Systems*, 35, 245-258.
- Atsalakis, G. S., & Valavanis, K. P. (2009a). Forecasting stock market short-term trends using a neuro-fuzzy based methodology. *Expert Systems with Applications*, 36(7), 10696-10707.
- Ballings, M., Van den Poel, D., Hespeels, N., & Gryp, R. (2015). Evaluating multiple classifiers for stock price direction prediction. *Expert Systems with Applications*, 42(20), 7046-7056.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2), 123-140.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L.F., Nobrega, J. P., & Oliveira, A. L.I. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55, 194-211.
- Chang, P.C., & Liu, C.H. (2008). A TSK type fuzzy rule based system for stock price prediction. *Expert Systems with Applications*, 34(1), 135-144.

- Chauvin, Y., & Rumelhart, D. E. (1995). *Backpropagation: theory, architectures, and applications*. Psychology Press.
- Cogley, T., & Nason, J. M. (1995). Effects of the Hodrick-Prescott filter on trend and difference stationary time series Implications for business cycle research. *Journal of Economic Dynamics and control*, 19(1), 253-278.
- Cubiles-De-La-Vega, M.D., Blanco-Oliver, A., Pino-Mejías, R. & Lara-Rubio, J. (2013). Improving the management of microfinance institutions by using credit scoring models based on Statistical Learning techniques. *Expert Systems with Applications*, 40 (17), 6910-6917.
- de Oliveira, F. A., Nobre, C. N., & Zárata, 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(good), 7596-7606.
- Dietterich, T. G. (2000). *Ensemble methods in machine learning*. Paper presented at the International workshop on multiple classifier systems.
- Esfahanipour, A., & Aghamiri, W. (2010). Adapted neuro-fuzzy inference system on indirect approach TSK fuzzy rule base for stock market analysis. *Expert Systems with Applications*, 37(7), 4742-4748.
- Fama, E. F. (1995). Random walks in stock market prices. *Financial analysts journal*, 51(1), 75-80.
- Fama, E. F., & Malkiel, B. G. (1970). Efficient capital markets: A review of theory and empirical work. *The journal of finance*, 25(2), 383-417.
- Ferreira, T. A.E., Vasconcelos, G. C., & Adeodato, P. J. L. (2008). A new intelligent system methodology for time series forecasting with artificial neural networks. *Neural Processing Letters*, 28(2), 113-129.
- Ghasemiyeh, R., Moghdani, R. & Sana, S. S. (2017). A Hybrid Artificial Neural Network with Metaheuristic Algorithms for Predicting Stock Price. *Cybernetics and Systems*, 48(4), 365-392.
- Goodarzi, M., Yakideh, K., & Mahfoozi, Gh. (2017). Portfolio optimization by synthesis of cross efficiency and Game theory. *Industrial Management Journal*, 4(8), 685-706. (in Persian)
- Guresen, E., Kayakutlu, G., & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38(8), 10389-10397.
- Hansen, L. K., & Salamon, P. (1990). Neural network ensembles. *IEEE transactions on pattern analysis and machine intelligence*, 12(10), 993-1001.
- Hassan, M.D.R. (2009). A combination of hidden Markov model and fuzzy model for stock market forecasting. *Neurocomputing*, 72(16), 3439-3446.
- Kara, Y., Boyacioglu, A.M., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, 38(5), 5311-5319.
- Khashei, M., Bijari, M., & Raissi Ardali, Gh. A. (2009). Improvement of auto-regressive integrated moving average models using fuzzy logic and artificial neural networks (ANNs). *Neurocomputing*, 72-128(4), 956-967.

- Li, X., Yang, L., Xue, F., & Zhou, H. (2017). Time series prediction of stock price using deep belief networks with intrinsic plasticity. *Paper presented at the Control And Decision Conference (CCDC), 2017 29th Chinese.*
- Lin, L., Wang, F., Xiaolong, X., & Shisheng, Z. (2017). Random forests-based extreme learning machine ensemble for multi-regime time series prediction. *Expert Systems with Applications, 83*, 164-176.
- Lo, A. W., & MacKinlay, A. C. (1988). Stock market prices do not follow random walks: Evidence from a simple specification test. *The Review of Financial Studies, 1*(1), 41-66.
- Maknickienė, N. (2016). Prediction Capabilities of Evolino RNN Ensembles. In *Computational Intelligence* (pp. 473-485): Springer.
- Monadjemi, S.A., Abzari, M., & Rayati-Shavazi, A. (2009). Modeling of Stock Price Forecasting in Stock Exchange Market, using Fuzzy Neural Networks and Genetic Algorithms. *Qualitative Economics, 6*(3), 1-26. (in Persian)
- Nikbakht, M.R., & Sharifi, M. (2010). Predicting corporate bankruptcy using Artificial Neural Networks (ANN) in Tehran Stock Exchange (TSE). *Industrial Management Journal, 2*(4), 163-180. (in Persian)
- Niu, M., Hu, Y., Sun, Sh., & Liu, Y. (2018). A novel hybrid decomposition-ensemble model based on VMD and HGWO for container throughput forecasting. *Applied Mathematical Modelling, 57*, 163-178.
- Ravi, V., Pradeepkumar, D., & Deb, K. (2017). Financial time series prediction using hybrids of chaos theory, multi-layer perceptron and multi-objective evolutionary algorithms. *Swarm and Evolutionary Computation, 36*, 136-149.
- Saeedi, H., & Mohammadi, Sh. (2012). Prediction Fluctuations in market returns using hybrid models of GARCH and Neural Network. *Quarterly Journal of Securities Exchange, 4*(16), 153-174. (in Persian)
- Sharifisalim, A., Momeni, M., Modaress-Yazdi, M., & Raei, R. (2015). Designing a Multi-objective Stochastic programming model for portfolio selection. *Industrial Management Journal, 7*(3), 489-510. (in Persian)
- Si, Y.W., & Yin, J. (2013). OBST-based segmentation approach to financial time series. *Engineering Applications of Artificial Intelligence, 26*(10), 2581-2596.
- Ticknor, J. L. (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications, 40*(14), 5501-5506.
- Tkáč, M., & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing, 38*(1), 788-804.
- Tsai, C.F., Lin, Y.C., Yen, D. C., & Chen, Y.M. (2011). Predicting stock returns by classifier ensembles. *Applied Soft Computing, 11*(2), 2452-2459.
- Wang, G., Hao, J., Ma, J., & Jiang, H. (2011). A comparative assessment of ensemble learning for credit scoring. *Expert Systems with Applications, 38*(1), 223-230.
- Xiao, Y., Xiao, J., Lu, F., & Wang, Sh. (2013). Ensemble ANNs-PSO-GA Approach for Day-ahead Stock E-exchange Prices Forecasting. *International Journal of Computational Intelligence Systems, 6*(1), 96-114.

- Yan, D., Zhou, Qi, Wang, J., & Zhang, N. (2017). Bayesian regularisation neural network based on artificial intelligence optimisation. *International Journal of Production Research*, 55(8), 2266-2287.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- Zhong, X, & Enke, D. (2017). Forecasting daily stock market return using dimensionality reduction. *Expert Systems with Applications*, 67, 126-139.