



Feature Selection for the Prediction Model of the Tehran Stock Exchange Index by Dimensionality Reduction Techniques

Somayeh Mohebi

Ph.D. Candidate, Department of Financial Management, Faculty of Management and Accounting, Shahid Beheshti University, Tehran, Iran. E-mail: so_mohebi@sbu.ac.ir

Mohamad Esmail Fadaeinejad *

*Corresponding Author, Associate Prof., Department of Financial Management and Insurance, Faculty of Management & Accounting, Shahid Beheshti University, Tehran, Iran. E-mail: m-fadaei@sbu.ac.ir

Mohamad Osoolian

Assistant Prof., Department of Financial Management and Insurance, Faculty of Management & Accounting, Shahid Beheshti University, Tehran, Iran. E-mail: m_osoolian@sbu.ac.ir

Mohamad Reza Hamidzadeh

Prof., Department of Business Management, Faculty of Management & Accounting, Shahid Beheshti University, Tehran, Iran. E-mail: hamidzadeh@sbu.ac.ir

Abstract

Objective: The main purpose of this study is to select an appropriate model for daily prediction of the total index of the Tehran Stock Exchange (TEDPIX). In this regard, dimension reduction techniques have been used to select effective and representative features to increase the accuracy of the selected model.

Methods: Since dimensionality reduction can be performed by two different methods (feature selection and extraction), in this study, two methods were used simultaneously to select the appropriate features of the prediction model. Hence, the MID algorithm was used to select the features, and the PCA algorithm was used to extract them. In this regard, after collecting 34 financial and economic features affecting the stock market, the features were prioritized by the MID algorithm. Then, the appropriate model was selected by comparing the performance of two different neural network models called RBF and DNN, which are respectively the most important and innovative of the extant models. Then, using two types of dimensionality reduction techniques, the prediction accuracy of the selected model was examined. The appropriate method for selecting the input features of the prediction model was identified, accordingly.

Results: Analysis of the obtained results showed that the RBF model comes with more accuracy in the daily prediction of the Tehran Exchange Dividend and Price Index. Also, by comparing the performance of the two types of dimensionality reduction techniques, it was found that compared with the PCA algorithm, the MID algorithm brings better results in selecting the input variables of the RBF model. Therefore, according to the priority of features with the MID algorithm and the pattern of changing the level of error by increasing the number of features in the RBF model, the ISF-MID algorithm was proposed to select the appropriate features of the stock index prediction model. Using this algorithm, with the minimum number of features, can end in the highest accuracy in predicting the total index of the Tehran Stock Exchange.

Conclusion: The proposed method can identify, prioritize and select appropriate features for the prediction model, due to the simplicity and effectiveness of its use. It can also be useful in various areas of modeling, including the capital market, foreign exchange market, etc.

Keywords: Dimensionality reduction technique, Deep neural network, Prediction model.

Citation: Mohebi, Somayeh; Fadaeinejad, Mohamad Esmail; Osoolian, Mohamad & Hamidzadeh, Mohamad Reza (2022). Feature Selection for the Prediction Model of the Tehran Stock Exchange Index by Dimensionality Reduction Techniques. *Financial Research Journal*, 24(4), 577-601. <https://doi.org/10.22059/FRJ.2021.325675.1007202> (in Persian)

Financial Research Journal, 2022, Vol. 24, No.4, pp. 577-601
Published by University of Tehran, Faculty of Management
<https://doi.org/10.22059/FRJ.2021.325675.1007202>
Article Type: Research Paper
© Authors

Received: July 15, 2021
Received in revised form: May 07, 2022
Accepted: October 26, 2022
Published online: January 19, 2023



انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی شاخص بورس اوراق بهادار تهران بر مبنای تکنیک کاهش ابعاد

سمیه محبی

دانشجوی دکتری، گروه مدیریت مالی، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: so_mohebi@sbu.ac.ir

محمد اسماعیل فدائی نژاد*

* نویسنده مسئول، دانشیار، گروه مدیریت مالی و بیمه، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی تهران، ایران. رایانامه: m-fadaei@sbu.ac.ir

محمد اصولیان

استادیار، گروه مدیریت مالی و بیمه، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: m_osoolian@sbu.ac.ir

محمدرضا حمیدی زاده

استاد، گروه مدیریت بازرگانی، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: m-hamidizadeh@sbu.ac.ir

چکیده

هدف: هدف اصلی این پژوهش، انتخاب مدل مناسب برای پیش‌بینی روزانه شاخص کل بورس اوراق بهادار تهران است. در این راستا، از تکنیک‌های کاهش ابعاد، جهت انتخاب ویژگی‌های مؤثر و معرف، به منظور افزایش دقت مدل انتخابی استفاده شده است.

روش: با توجه به اینکه کاهش ابعاد می‌تواند با دو روش متفاوت (انتخاب و استخراج ویژگی) اجرا شود، در این پژوهش، هر دو روش برای انتخاب ویژگی‌های مناسب مدل پیش‌بینی به کار برده شده است؛ به طوری که برای انتخاب ویژگی‌ها از الگوریتم MID و برای استخراج ویژگی‌ها از الگوریتم PCA استفاده می‌شود. در این راستا، پس از جمع‌آوری ۳۴ ویژگی مالی و اقتصادی مؤثر بر بازار سهام، به اولویت‌بندی ویژگی‌ها با الگوریتم MID اقدام شده است، سپس با مقایسه عملکرد دو مدل مختلف شبکه عصبی با نام‌های RBF و DNN که به ترتیب از مهم‌ترین و بدیع‌ترین مدل‌ها هستند، مدل مناسب انتخاب شده است. در ادامه با استفاده از دو نوع تکنیک کاهش ابعاد، دقت پیش‌بینی مدل انتخابی بررسی شده و روش مناسب برای انتخاب ویژگی‌های ورودی مدل پیش‌بینی شناسایی شده است.

یافته‌ها: با تحلیل نتایج به دست آمده مشخص شد که مدل RBF در پیش‌بینی روزانه شاخص کل بورس اوراق بهادار تهران دقت بیشتری دارد. همچنین با مقایسه عملکرد دو نوع تکنیک کاهش ابعاد، مشخص شد که الگوریتم MID نسبت به الگوریتم PCA در انتخاب متغیرهای ورودی مدل RBF نتیجه بهتری را ارائه کرده است. بنابراین با توجه به اولویت‌بندی ویژگی‌ها با الگوریتم MID و الگوی تغییر مقدار خطا با افزایش تعداد ویژگی‌ها در مدل RBF، الگوریتم ISF_MID، برای انتخاب ویژگی‌های مناسب مدل پیش‌بینی شاخص بورس پیشنهاد شد. با استفاده از این الگوریتم می‌توان با کمترین تعداد ویژگی، بیشترین دقت را در پیش‌بینی شاخص بورس به دست آورد.

نتیجه‌گیری: روش پیشنهاد شده در این پژوهش جهت شناسایی، اولویت‌بندی و انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی، با توجه به سادگی و اثربخشی استفاده از آن، می‌تواند در حوزه‌های مختلف مدل‌سازی، از جمله بازار سرمایه، بازار ارز و مانند آن‌ها مفید واقع شود.

کلیدواژه‌ها: تکنیک کاهش ابعاد، شبکه عصبی عمیق، تابع پایه شعاعی، تحلیل مؤلفه‌های اصلی.

استناد: محبی، سمیه؛ فدائی نژاد، محمد اسماعیل؛ اصولیان، محمد و حمیدی زاده، محمدرضا (۱۴۰۱). انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی شاخص بورس اوراق بهادار تهران بر مبنای تکنیک کاهش ابعاد. *تحقیقات مالی*، ۲۴(۴)، ۵۷۷-۶۰۱.

مقدمه

در بازارهای مالی، موفقیت سرمایه‌گذار به کیفیت اطلاعات و سرعت تصمیم‌گیری وی بستگی دارد. بنابراین پیش‌بینی در این بازارها بسیار مهم است؛ زیرا پیش‌بینی‌های دقیق به افراد این امکان را می‌دهد آگاهانه درباره سرمایه‌گذاری‌ها تصمیم‌گیری کنند و ریسک‌ها را کاهش دهند. طبق نظریه بازار کارا، بازارهای سهام تمام اطلاعات موجود را منعکس می‌کنند و فرضیه گام تصادفی را دنبال می‌کنند، از این رو پیش‌بینی آن‌ها بسیار دشوار است. با این حال، بسیاری از مطالعات تجربی حاکی از آن است که بازارهای مالی بلافاصله با اطلاعات تازه منتشر شده خود را تطبیق نمی‌دهند و تأثیرهای روان‌شناختی فعالان مختلف بازار، بازارهای مالی را تا حدی پیش‌بینی‌پذیر می‌کند (سرولو - رویو و گویجارو^۱، ۲۰۲۰). بنابراین در دهه‌های گذشته برخی سازوکارهای محاسباتی نرم و آماری برای پشتیبانی از تصمیمات سرمایه‌گذاران در بخش‌های مختلف بازار مالی توسط محققان در حوزه‌های مالی، مهندسی و ریاضی پیشنهاد شده‌اند (یو، کیم و جان^۲، ۲۰۰۵).

از آنجا که بازارهای مالی یک سیستم پویا، پیچیده، تکاملی، نویزی، غیرخطی و غیرپارامتریک هستند (هوانگ و تسای^۳، ۲۰۰۹) و تحت تأثیر عوامل مختلفی مانند وضعیت اقتصادی، متغیرهای خاص صنعت، چشم‌انداز شرکت، انتظارات سرمایه‌گذاران و سیاست‌های دولت قرار دارند، تحلیل و پیش‌بینی این بازارها بسیار پیچیده است (ژونگ و انکه^۴، ۲۰۱۷). بنابراین روش‌های محاسبات نرم، سازوکارهای سازگارتر و انعطاف‌پذیرتر برای بهبود دقت پیش‌بینی هستند؛ زیرا مدل‌هایی داده‌محور، غیرپارامتری و خودتطبیقی هستند که نسبت به مدل‌های آماری سنتی به داده‌های تاریخی کمتری نیاز دارند (چنگ و وی^۵، ۲۰۱۴). سیستم‌های خبره، سیستم‌های فازی و شبکه‌های عصبی مصنوعی، از جمله تکنیک‌های محاسباتی نرم هستند که با موفقیت نسبی در مدل‌سازی و پیش‌بینی بخش‌های متعدد بازارهای مالی به کار گرفته شده‌اند (لی^۶، ۲۰۰۹).

سرولو - رویو و گویجارو (۲۰۲۰) از پنج مدل مختلف یادگیری ماشین استفاده کردند و نشان دادند که تمامی مدل‌ها به دقت پیش‌بینی بیشتر از حد متوسط دست یافتند. اخیراً، رویکردهای یادگیری عمیق با نتایجی ظاهر شده‌اند که نسبت به هم‌تایان یادگیری ماشین سنتی عملکرد بهتری دارند (سزر، گودلک و اوزبایوگلو^۷، ۲۰۲۰). با این حال، کاربرد روش‌های یادگیری عمیق در زمینه پیش‌بینی‌های مالی یک حوزه نسبتاً کشف نشده باقی مانده است. یکی از چالش‌های اصلی در این پژوهش، بررسی عملکرد شبکه‌های عصبی مصنوعی با ساختاری عمیق در پیش‌بینی شاخص بورس است. از طرفی، اگر از یک شبکه عصبی مصنوعی انتظار می‌رود تا پیش‌بینی دقیق و کارآمد را تولید کند، ضروری است تا مرتبط‌ترین و تأثیرگذارترین ویژگی‌ها به‌عنوان متغیرهای ورودی مدل پیش‌بینی انتخاب شود. همان‌طور که ذکر شد بازارهای سهام،

1. Cervelló-Royo & Guijarro
2. Yoo, Kim, & Jan
3. Huang & Tsai
4. Zhong & Enke
5. Cheng & Wei
6. Lee
7. Sezer, Gudelek & Ozbayoglu

تحت تأثیر عوامل مختلفی هستند که ممکن است به عنوان متغیرهای ورودی مدل پیش‌بینی مورد استفاده قرار گیرند. انتخاب اینکه کدام متغیرهای ورودی برای مدل پیش‌بینی مؤثرترند، کار ساده‌ای نیست؛ زیرا در ادبیات موضوع و منابع، هیچ اجماعی در خصوص بهترین متغیرهای ورودی برای مدل پیش‌بینی وجود ندارد. به‌منظور کمک به تصمیم‌گیری درباره اینکه کدام مجموعه متغیر برای پیش‌بینی‌های مالی مناسب‌تر است و برای کار مدل‌سازی زائد و/یا غیرمرتبط نیست، برخی تحقیقات از فرایندهای پیش‌پردازش روی داده‌های ورودی قبل از مرحله آموزش استفاده کرده‌اند. یکی از بهترین روش‌های پیش‌پردازش روی داده‌ها استفاده از سازوکارهای استخراج^۱ یا انتخاب^۲ ویژگی‌هاست. مزیت اصلی استخراج یا انتخاب ویژگی کاهش ابعاد است که در نتیجه، تلاش‌های محاسباتی مدل هوشمند و همچنین خطر بیش‌برازش را کاهش می‌دهد (تسای و هسیائو^۳، ۲۰۱۰).

در این تحقیق، به‌منظور ارائه یک مجموعه ویژگی مناسب برای بهبود عملکرد مدل پیش‌بینی، انتخاب ویژگی‌ها با استفاده از تکنیک‌های کاهش ابعاد انجام می‌شود. برخلاف مطالعات موجود که از یک تکنیک انتخاب ویژگی استفاده می‌کنند، مانند ژونگ و انکه (۲۰۱۹)، گوندوز، کتلپه و یاسلان^۴ (۲۰۱۷) و لین، گوا و هو^۵ (۲۰۱۳)، در این مطالعه هر دو روش کاهش ابعاد (انتخاب و استخراج ویژگی) که مفروضات جداگانه‌ای برای انتخاب ویژگی‌های مناسب دارند، هم‌زمان مورد استفاده و ارزیابی قرار می‌گیرند. همچنین تا جایی که اطلاع داریم، این اولین تلاش برای بررسی تأثیر انتخاب ویژگی در مدل شبکه عصبی عمیق برای پیش‌بینی شاخص بورس اوراق بهادار تهران است. با توجه به هدف اصلی این پژوهش که تبیین مراحل مورد نیاز برای انتخاب مدل پیش‌بینی و شناسایی ویژگی‌های مؤثر برای مدل انتخابی، به‌منظور انجام موفقیت‌آمیز پیش‌بینی شاخص بورس است، ابتدا مجموعه‌ای گسترده از ۳۴ متغیر مالی و اقتصادی مؤثر بر بازار سهام را جمع‌آوری شده است، سپس دو مدل مختلف شبکه عصبی مصنوعی به نام‌های تابع پایه شعاعی (RBF)^۶ و شبکه عصبی عمیق (DNN)^۷ که به ترتیب از مهم‌ترین و بدیع‌ترین مدل‌های پیش‌بینی هستند، برای پیش‌بینی روزانه شاخص بورس مقایسه شده و مدل مناسب انتخاب می‌شود. در ادامه، به‌منظور انتخاب یک مجموعه ویژگی مطلوب از میان مجموعه داده‌های اصلی برای مدل پیش‌بینی، هم‌زمان از دو شیوه متفاوت کاهش ابعاد استفاده می‌شود؛ به‌طوری‌که در روش انتخاب ویژگی‌ها، از یک روش تخمین کمینه افزونگی، بیشینه وابستگی (mRMR)^۸ و برای استخراج ویژگی‌ها، از تحلیل مؤلفه‌های اصلی (PCA)^۹ استفاده می‌شود. با انتخاب مدل مناسب برای پیش‌بینی شاخص بورس و ارزیابی عملکرد دو نوع تکنیک کاهش ابعاد، الگوریتمی به‌منظور انتخاب ویژگی‌های مؤثر با هدف فیلتر کردن متغیرهای ورودی بی‌ربط و اضافی برای کاهش پیچیدگی و بهبود دقت مدل پیش‌بینی پیشنهاد می‌گردد و براساس آن، ویژگی‌های مناسب

1. Feature Selection
2. Feature Extraction
3. Tsai, & Hsiao
4. Gündüz, Cataltepe & Yaslan
5. Lin, Guo & Hu
6. Radial Basis Function
7. Deep Neural Network
8. Minimum Redundancy Maximum Relevance
9. Principal Component Analysis

به‌عنوان ورودی‌های مدل پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران شناسایی می‌گردند. بنابراین مهم‌ترین سهم علمی این پژوهش، ارائه یک متدولوژی مناسب به‌منظور افزایش دقت پیش‌بینی شاخص بورس است.

پیشینه نظری پژوهش

یکی از مهم‌ترین روش‌های یادگیری هوشمند که در سال‌های اخیر در بازارهای مالی بسیار مورد استفاده قرار گرفته و به نتایج مطلوبی نیز دست یافته است، شبکه‌های عصبی مصنوعی است. اخیراً در مطالعه‌ای، هنریکه، سوبریرو و کیمورا^۱ (۲۰۱۹)، ۵۴۷ مقاله را بررسی کردند و دریافتند که تقریباً ۷۴ درصد از مطالعات بررسی شده حداقل از نوعی شبکه عصبی مصنوعی برای پیش‌بینی بازار سهام استفاده می‌کنند. شبکه‌های عصبی قادرند که روابط غیرخطی را در بین عوامل بازار مربوطه، بدون هیچ دانش قبلی یا فرضیه‌های آماری برای داده‌های ورودی را به‌دست آورند (آتسالکیس و والوانیس^۲، ۲۰۰۹). بنابراین از آن‌ها در طبقه‌بندی، پیش‌بینی و شناخت الگو بسیار استفاده می‌شود (هو، تانگ، ژانگ و وانگ^۳، ۲۰۱۸). یکی از اولین کارهایی که از شبکه‌های عصبی مصنوعی در بازارهای مالی استفاده کرده، مقاله کیموتو، آساکاوا، تائوکا و یودا^۴ (۱۹۹۰) است. آن‌ها از شبکه‌های عصبی برای پیش‌بینی شاخص بورس توکیو استفاده کردند. طبق گفته نلسون و ایلینگورث^۵ (۱۹۹۱)، روش‌های زیادی برای سازمان‌دهی شبکه‌های عصبی وجود دارد؛ اما معمولاً ۲۴ مدل از شبکه‌های مصنوعی مورد استفاده قرار می‌گیرند. ساختار شبکه عصبی را می‌توان از نظر نورودینامیک و معماری توصیف کرد. نورودینامیک به خصوصیات یک نرون مصنوعی گفته می‌شود که ترکیبی از ورودی، تولید خروجی، نوع توابع انتقال، روش‌های وزن‌دار کردن را شامل می‌شود. معماری شبکه که گاهی به آن توپولوژی شبکه نیز گفته می‌شود، خصوصیات شبکه مانند انواع اتصال بین نرون‌های مصنوعی، تعداد نرون‌ها و تعداد لایه‌ها را تعریف می‌کند.

یکی از رایج‌ترین شبکه‌های عصبی مصنوعی، تابع پایه شعاعی (RBF) است. این نوع شبکه‌ها از توابع پایه شعاعی، به‌عنوان توابع فعال‌ساز استفاده می‌کنند. خروجی شبکه، ترکیبی خطی از توابع پایه شعاعی ورودی‌ها و پارامترهای نرون است. عملکرد یک شعاعی معمولی گوسی است، ویژگی مشخص آن‌ها این است که با فاصله‌گرفتن از یک نقطه مرکزی، پاسخ آن‌ها به‌صورت یکنواخت کاهش (یا افزایش) می‌یابد. RBF نسبت به شبکه عصبی پرسپترون چندلایه (MLP)^۶ مزایای زیادی دارد. از جمله اینکه آن‌ها می‌توانند هر تابع غیرخطی را با استفاده از تنها یک لایه پنهان که برخی از تصمیمات مربوط به طراحی در مورد تعداد لایه‌ها را حذف می‌کند، مدل‌سازی کنند. همچنین، تبدیل خطی ساده در لایه خروجی را می‌توان با استفاده از تکنیک‌های سنتی مدل‌سازی خطی، به‌طور کامل بهینه‌سازی کرد که ضمن سریع‌بودن، فاقد مشکلاتی مانند کمینه محلی هستند که برای تکنیک‌های آموزش MLP محدودیت ایجاد می‌کنند.

1. Henrique, Sobreiro & Kimura
2. Atsalakis & Valavanis
3. Hu, Tang, Zhang & Wang
4. Kimoto, Asakawa, Takeoka & Yoda
5. Nelson & Illingworth
6. Multi-Layer Perceptron

بنابراین RBF می‌تواند خیلی سریع آموزش ببیند. داش و داش^۱ (۲۰۱۶) و گو، یی، یانگ و زنگ^۲ (۲۰۱۷) با استفاده از تکنیک RBF مدل‌های خود را آموزش دادند.

اخیراً توجه انجمن‌های یادگیری ماشین و تشخیص الگو، به استفاده از روش‌های مختلف برای یادگیری سلسله‌مراتبی ویژگی‌های مفید از تعداد زیادی داده، جلب شده است (بنگیو، کورویل، و وینسنت^۳، ۲۰۱۳). هدف اصلی این روش‌ها، مدل‌سازی داده‌های پیچیده دنیای واقعی به‌وسیله استخراج ویژگی‌های مناسب از اطلاعات مرتبط است (هینتون، اوسیندرو و ته^۴، ۲۰۰۶). استخراج و شناسایی الگوها، از طریق یک توپولوژی شبکه غیرخطی عمیق انجام می‌گیرد که در آن لایه‌هایی از نمایش ویژگی می‌توانند روی هم قرار بگیرند و شبکه‌های عمیقی که توانایی مدل‌سازی ساختارهای پیچیده‌ای از داده‌ها را دارند، شکل دهند (لیروکس، و بنگیو^۵، ۲۰۰۸). یادگیری عمیق در انجام کارهایی نظیر طبقه‌بندی (لی، گروس، رانگانات و نگ^۶، ۲۰۰۹)، تشخیص گفتار (ژانگ و وو^۷، ۲۰۱۳) و کاهش ابعاد (هینتون و سالاخودینوف^۸، ۲۰۰۶) به‌طور موفقیت‌آمیز استفاده شده‌اند. با این حال، کاربرد روش‌های یادگیری عمیق در زمینه پیش‌بینی‌های مالی یک حوزه نسبتاً کشف نشده باقی مانده است.

در میان محققان مالی، چالشی مطرح است که آیا استفاده از روش‌های یادگیری عمیق برای پیش‌بینی‌های مالی، مدل‌سازی سری‌های زمانی پیچیده با ابعاد بالا و در محیط واقعی پرنویز از طریق نمایش عمیق داده‌ها امکان‌پذیر است؟ برخی از رویکردهای یادگیری عمیق درباره مدل‌سازی سری‌های زمانی در پژوهش کورموتو، کیمورا، کوبایاشی و اوبایاشی^۹ (۲۰۱۴) ارائه شده است که مدل پیش‌بینی توسط شبکه باور عمیق با دو ماشین بولتزمن محدود ساخته و با مدل‌سازی سری‌های زمانی آشوب ارزیابی می‌شود. نتایج پیش‌بینی نشان می‌دهد روش پیشنهادی در مقایسه با MLP و ARIMA دقت پیش‌بینی بیشتری دارد. در پژوهشی که توسط دینگ، ژانگ، لیو و دوان^{۱۰} (۲۰۱۵) انجام شد، ترکیبی از شبکه عصبی تانسور و شبکه عصبی پیچشی عمیق برای مدل‌سازی هر دو اثرهای کوتاه‌مدت و بلندمدت رویدادها بر تغییرات قیمت سهام پیشنهاد شد.

از طرفی، اگر از یک شبکه عصبی مصنوعی انتظار می‌رود تا پیش‌بینی دقیق و کارآمد را تولید کند، ضروری است تا ورودی‌های بسیار مؤثر و معرف^{۱۱} انتخاب شود. این نوع انتخاب وظیفه اصلی تکنولوژی کاهش ابعاد است. کاهش ابعاد می‌تواند با دو شیوه متفاوت اجرا شود:

۱. انتخاب مرتبط‌ترین متغیرها از مجموعه داده‌های اصلی که انتخاب ویژگی نامیده می‌شود؛

1. Dash & Dash
2. Guo, Ye, Yang & Zeng
3. Bengio, Courville & Vincent
4. Hinton, Osindero & Teh
5. Le Roux & Bengio
6. Lee, Grosse, Ranganath, & Ng
7. Zhang & Wu
8. Hinton & Salakhutdinov
9. Kuremoto, Kimura, Kobayashi, & Obayashi
10. Ding, Zhang, Liu, & Duan
11. Representative

۲. از طریق تولید یک گروه کوچک‌تر از متغیرهای جدید که هرکدام ترکیب مشخصی از متغیرهای ورودی قدیمی‌ترند که استخراج ویژگی نامیده می‌شود.

تمایز مهمی دربارهٔ انتخاب ویژگی و استخراج ویژگی وجود دارد. سازوکارهای انتخاب ویژگی که انتخاب زیرمجموعه ویژگی نیز نامیده می‌شوند، برخلاف روش‌های مبتنی بر استخراج ویژگی، معنای اصلی ویژگی‌ها را بعد از کاهش حفظ می‌کنند. در صورتی که سازوکارهای استخراج ویژگی سعی می‌کنند، مجموعه ویژگی‌های اصلی را به فضای ویژگی‌هایی با ابعاد پایین انتقال دهند، بدون اینکه ماهیت مسئله تغییر کند (کاوالکانت و همکاران^۱، ۲۰۱۶). اما هر دو روش انتخاب و استخراج ویژگی را می‌توان به‌منظور انتخاب بهترین ویژگی‌های نماینده از مجموعه داده‌ها که بعد ورودی را کاهش داده و در نتیجه زمان آموزش را به حداقل می‌رسانند، به کار برد.

برای انتخاب ویژگی، راه‌حل‌ها و الگوریتم‌های فراوانی ارائه شده است. از مهم‌ترین روش‌های انتخاب ویژگی روش جست‌وجوی مکاشفه‌ای^۲ است. در جست‌وجوی مکاشفه‌ای از بحث هم‌بستگی بین ویژگی‌های ورودی با یکدیگر و نیز با ویژگی خروجی، برای انتخاب ویژگی‌ها استفاده می‌شود که در علم آمار با دو اصطلاح توضیح داده می‌شود. اولی بحث ارتباط^۳ است که وابستگی بین ویژگی انتخابی به‌عنوان ورودی با خروجی مدل را نشان می‌دهد و دومی افزونگی^۴ است که وابستگی بین ویژگی انتخابی به‌عنوان ورودی را با ویژگی‌هایی که تاکنون به‌عنوان ورودی مدل انتخاب شده است، نشان می‌دهد. در این راستا، از یک الگو دقیق استفاده می‌شود که به‌حداکثر شدن وابستگی بین ویژگی ورودی با ویژگی خروجی و حداقل شدن وابستگی بین ویژگی که قرار است انتخاب شود با ویژگی‌هایی که تاکنون انتخاب شده‌اند، منجر می‌گردد. در روش استخراج ویژگی، فضای یک مسئله به فضای دیگر نگاشت می‌یابد. هدف از نگاشت، انتقال یک مسئله از فضایی با تعداد بسیار زیادی ویژگی به فضایی است که تعداد ویژگی‌های کمتری دارد. در این نگاشت ماهیت مسئله به‌هیچ‌عنوان تغییر نمی‌کند و فقط در یک فضایی با ابعاد کمتر، همان داده‌ها وجود دارد. تحلیل مؤلفه‌های اصلی (PCA) قدیمی‌ترین و شناخته‌ترین روش آماری برای استخراج ویژگی‌های مهم از مجموعه داده‌هایی با ابعاد گسترده است. این متدولوژی به کار پیرسون (۱۹۰۱)، برمی‌گردد و مبتنی بر ایدهٔ تعریف یک سیستم یا فضای هماهنگ جدید است که داده‌های خام می‌توانند با استفاده از داده‌های بسیار کمتری بیان شوند، بدون آنکه اطلاعات قابل توجهی از دست برود.

پیشینهٔ تجربی پژوهش

روند مطالعات در پژوهش‌های داخلی و خارجی، برتری انواع شبکه‌های عصبی مصنوعی را به سایر تکنیک‌های محاسباتی نشان می‌دهد. در ادامه، به معرفی چند نمونه از مطالعاتی پرداخته می‌شود که اخیراً انجام شده است و با موضوع پژوهش بیشترین ارتباط را دارند.

ذوالفقاری، سحابی و بختیاران (۱۳۹۹)، مدلی ترکیبی از شبکه یادگیری عمیق و مدل‌های منتخب خانواده

1. Cavalcante et al.
2. Heuristic
3. Relevance
4. Redandency

GARCH جهت پیش‌بینی بازدهی روزانه شاخص کل بورس اوراق بهادار تهران معرفی کردند. نتایج تحقیق نشان می‌دهد که مدل‌های ترکیبی نسبت به مدل‌های تک ساختاری دقت پیش‌بینی بالاتری دارند و مدل-ARMAX EGARCH-RNN-GED نسبت به ۲۳ مدل دیگر ترکیبی، خطای پیش‌بینی کمتری دارد ($RMSE=0/33$). همچنین دو متغیر مستقل قیمت نفت و نرخ دلار در ساختار مدل ترکیبی، کمک فراوانی در پیش‌بینی دقیق‌تر داده‌های مالی می‌کنند.

در پژوهش تهرانی، حیرانی و منصوری (۱۳۹۸)، سعی شده است تا دقت مدل ARMA، شبکه‌های عصبی مصنوعی مختلف و شبکه‌های عصبی فازی در پیش‌بینی قیمت بر مبنای مدل ۵ عاملی فاما و فرنچ در بورس اوراق بهادار تهران ارزیابی شود. این مدل‌ها با توجه به ۶ معیار ارزیابی دقت پیش‌بینی آزمون شده‌اند. نتایج به‌دست آمده نشان داد که شبکه عصبی تابع پایه شعاعی نسبت به دیگر مدل‌های شبکه‌های عصبی و ARMA از دقت بالاتری برخوردار است. این نتایج با مطالعات منفرد، احمدعلی‌نژاد و مقالچی (۱۳۹۱)، و گوئرسن، کایاکوتلو و دایم^۱ (۲۰۱۱) مطابقت دارد.

صالحی و گرشاسبی (۱۳۹۸)، از الگوریتم رقابت استعماری به‌عنوان روش انتخاب ویژگی و شبکه فازی عصبی انطباق‌پذیر، به‌عنوان تابع پیش‌بینی‌کننده برای پیش‌بینی شاخص کل بورس اوراق بهادار تهران استفاده کردند. پس از ۸۰ دفعه اجرای مدل، تعداد ۱۰ ویژگی با بیشترین تأثیر در پیش‌بینی شاخص کل بورس انتخاب شد. براساس نتایج مشخص شد که بیشترین تأثیر مربوط به شاخص‌های اقتصادی و کمترین تأثیر مربوط به شاخص بورس بازارهای بین‌المللی است. افشاری راد، علوی و سینایی (۱۳۹۷) با هدف پیش‌بینی روند شاخص کل با روش‌های تحلیل تکنیکال پیش‌بینی سهام و روش‌های هوشمند یادگیری ماشین، به اولویت‌بندی و کاهش ابعاد روش‌های تحلیل تکنیکال اقدام کرده‌اند و برای این کار، روش Relief را که یکی از روش‌های انتخاب ویژگی است، به‌کار برده‌اند. سپس با ۵ روش هوشمند یادگیری ماشین، به پیش‌بینی روند شاخص کل بورس پرداخته‌اند و در نهایت، برای تصمیم‌گیری نهایی از روش رأی اکثریت استفاده کرده‌اند.

راعی، نیک عهد و حبیبی (۱۳۹۵)، در پژوهشی به‌منظور افزایش دقت پیش‌بینی شاخص بورس اوراق بهادار تهران، ترکیبی از روش‌های آماری و هوش مصنوعی را به‌کار برده‌اند. در این پژوهش از روش PCA برای پالایش اولیه داده‌ها استفاده شده است. نتایج به‌دست آمده نشان داد که پیش‌پردازش روی داده‌ها، خطای پیش‌بینی مدل را به‌طور قابل ملاحظه‌ای کاهش داده است.

گوندوز و کتلتپه^۲ (۲۰۱۵)، یک روش پیش‌بینی را پیشنهاد کردند که تحلیل مقالات خبری و قیمت‌های سهام را برای پیش‌بینی حرکات آینده بازار با هم ترکیب می‌کند. در این رویکرد، از یک روش انتخاب ویژگی به نام اطلاعات متقابل متعادل (BMI)^۳ به‌منظور شناسایی ویژگی‌های مرتبط‌تر برای تعیین جهت بازار استفاده شده است.

1. Guresen, Kayakutlu & Daim
2. Gunduz & Cataltepe
3. Balanced Mutual Information

چی و سوونگ^۱ (۲۰۱۶)، در تحقیقی به‌منظور پیش‌بینی جهت قیمت شاخص بازار سهام ژاپن از یک شبکه عصبی مصنوعی بهینه شده با الگوریتم‌های ژنتیک استفاده کردند. همچنین به‌منظور ارزیابی تأثیر نوع متغیر ورودی بر عملکرد مدل پیش‌بینی، دو نوع اساسی از متغیرهای ورودی مورد بررسی قرار گرفتند. براساس یافته‌ها مشخص شد که متغیرهای ورودی نوع دوم می‌توانند دقت پیش‌بینی بالاتری ایجاد کنند. بنابراین به این نتیجه رسیدند که با انتخاب مناسب متغیرهای ورودی، می‌توان دقت عملکرد شبکه‌های عصبی مصنوعی را افزایش داد.

سینگ و سریواستاوا^۲ (۲۰۱۷)، از PCA برای سرعت بخشیدن به آموزش مدل بدون از دست‌دادن دقت در صحت پیش‌بینی استفاده کردند. در این مقاله، آن‌ها قیمت سهام را با استفاده ترکیب دو تکنیک قدرتمند PCA و شبکه عصبی عمیق پیش‌بینی کردند، سپس نتایج خود را با شبکه عصبی تابع پایه شعاعی مقایسه کردند و نشان دادند دقت مدل پیشنهادی ۴/۸ درصد بهبود یافته است. ژونگ و انکه (۲۰۱۷)، برای پیش‌بینی بازده شاخص بورس، سه روش استخراج ویژگی را با ۶۰ داده مالی و اقتصادی به‌منظور ساده‌سازی و آرایش مجدد ساختار اصلی مورد استفاده قرار دادند. آن‌ها نتیجه گرفتند که استفاده از PCA نه تنها مقدار داده‌های مورد نیاز برای آموزش مدل‌ها را ساده می‌کند، بلکه باعث افزایش دقت کلی پیش‌بینی‌ها می‌شود و هیچ‌کدام از تکنیک‌های غیرخطی، استخراج ویژگی‌های مناسب را بهتر از PCA برای داده‌های جهان واقعی خوب اجرا نمی‌کنند.

لانگ، لو و کوئی^۳ (۲۰۱۹) در پژوهشی تحت عنوان «مهندسی ویژگی مبتنی بر یادگیری عمیق برای پیش‌بینی حرکت سهام»، مدلی جدید تحت عنوان شبکه عصبی چند فیلتری را برای استخراج ویژگی‌ها پیشنهاد دادند. برای ایجاد ساختار چند فیلتری هر دو نورون عصبی کانولوشنال و بازگشتی یکپارچه شده‌اند. براساس نتایج تجربی نشان دادند که مدل پیشنهادی از مدل‌های سنتی یادگیری ماشین، آماری و تک ساختاری بهتر عمل می‌کند.

الحق، زیب، لی و ژانگ^۴ (۲۰۲۱)، در مطالعه‌ای با عنوان «پیش‌بینی روند سهام روزانه با استفاده از انتخاب ویژگی چند فیلتری و یادگیری عمیق»، ویژگی‌های انتخاب شده توسط رگرسیون لجستیک منظم، ماشین بردار پشتیبانی و جنگل تصادفی را برای تولید زیرمجموعه ویژگی بهینه ترکیب کرده و سپس از یک مدل سازنده عمیق برای پیش‌بینی حرکات آینده قیمت سهام استفاده کردند.

سؤال‌های پژوهش

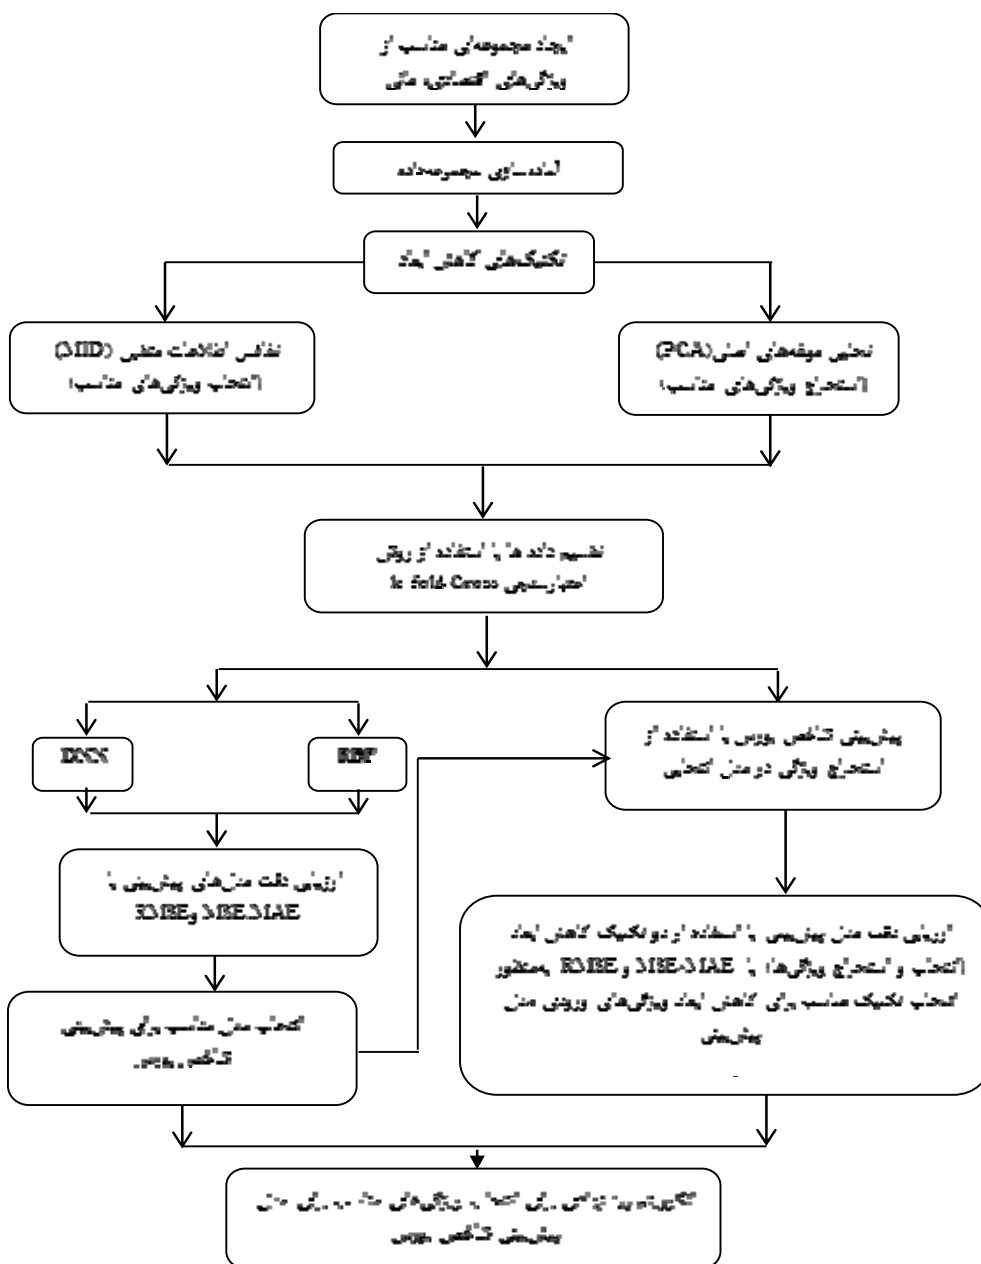
این پژوهش به‌دنبال پاسخ به سؤال‌های زیر است:

۱. کدام یک از مدل‌های شبکه عصبی مصنوعی به نام‌های تابع پایه شعاعی (RBF) و شبکه عصبی عمیق (DNN)، دقت بیشتری در پیش‌بینی شاخص بورس اوراق بهادار تهران دارد؟
۲. کدام یک از تکنیک‌های کاهش ابعاد، روش تخمین کمینه افزونگی، بیشینه وابستگی (mRMR) یا تحلیل

1. Qiu & Song
 2. Singh & Srivastava
 3. Long, Lu & Cui
 4. Ul Haq, Zeb, Lei & Zhang

مؤلفه‌های اصلی (PCA) تأثیر بیشتری در دقت عملکرد مدل پیش‌بینی شاخص بورس اوراق بهادار تهران دارد؟

۳. آیا الگوریتم پیشنهادی در این پژوهش در مقایسه با روش تخمین کمینه‌افزونی، بیشینه‌وابستگی (mRMR)، و تحلیل مؤلفه‌های اصلی (PCA)، عملکرد بهتری را در انتخاب ویژگی‌های مناسب برای پیش‌بینی شاخص بورس اوراق بهادار تهران ارائه می‌دهد؟
 برای پاسخ به سؤال‌های فوق مراحل نمایش داده در شکل ۱، انجام می‌شود.



شکل ۱. مراحل اجرای پژوهش

روش‌شناسی پژوهش

در این بخش از پژوهش، به صورت اجمالی مجموعه داده، تکنیک‌های مختلف کاهش ابعاد، مدل‌های مورد استفاده و معیارهای ارزیابی عملکرد مدل‌های پیش‌بینی، معرفی می‌شوند.

مجموعه داده

با توجه به اینکه در شبکه‌های عصبی مصنوعی افزایش تعداد داده‌ها موجب کسب نتایج دقیق‌تر می‌شود، داده‌های مالی و اقتصادی مورد استفاده در این پژوهش به صورت روزانه از تاریخ ۱۳۹۲/۱۰/۲۸ تا ۱۳۹۷/۵/۳۰ به مدت ۱۱۰۸ روز کاری بورس تهران جمع‌آوری شده است.

جدول ۱. فهرست ویژگی‌های مورد بررسی برای پیش‌بینی شاخص کل بورس اوراق بهادار تهران

نام متغیر	توضیح
بازده شاخص کل بورس در سه روز گذشته	$(TEDPIX(t-x) - TEDPIX(t-x-1)) / TEDPIX(t-x-1) \quad x=1,2,3$
تغییر نسبی حجم معاملات در سه روز گذشته	$(TV(t-x) - TV(t-x-1)) / TV(t-x-1) \quad x=1,2,3$
بازده شاخص ۵۰ شرکت فعال بورس در سه روز گذشته	$(IC50(t-x) - IC50(t-x-1)) / IC50(t-x-1) \quad x=1,2,3$
بازده شاخص ۳۰ شرکت بزرگ در سه روز گذشته	$(LCI30(t-x) - LCI30(t-x-1)) / LCI30(t-x-1) \quad x=1,2,3$
میانگین متحرک نمایی قیمت پایانی ۱۰، ۲۰، ۵۰ و ۲۰۰ روز گذشته	$p(t) * (2/(x+1)) + EMA_x(t-1) * (1-2/(x+1)) \quad x=10,20,50,200$
میانگین متحرک قیمت پایانی ۵، ۱۰، ۳۰ روز گذشته	$MA_{x-1} = \frac{\sum_{i=1}^x p_{x-i}}{n} \quad x=5,10,30$
تفاوت نسبی درصد بازده شاخص ۵، ۱۰، ۱۵ و ۲۰ روز گذشته	$(p(t) - p(t-x)) / p(t-x) * 100 \quad x=5,10,15,20$
شاخص سطح مقاومت قیمت برای ۳۰ و ۱۲۰ روز گذشته	$MPP = \frac{p - p_{min}}{p_{max} - p_{min}}$
تغییر قیمت نفت اوپک در ۳ روز گذشته	$(OP(t-x) - OP(t-x-1)) / OP(t-x-1) \quad x=1,2,3$
تغییر نرخ دلار در ۳ روز گذشته	$(D(t-x) - D(t-x-1)) / D(t-x-1) \quad x=1,2,3$
تغییر قیمت سکه طلا در ۳ روز گذشته	$(GP(t-x) - GP(t-x-1)) / GP(t-x-1) \quad x=1,2,3$

نرمال‌سازی مجموعه داده

برای نرمال‌سازی داده‌ها، یعنی یکسان کردن مقیاس آن‌ها، مقدار هر داده در بازه بین صفر و یک تعیین می‌شود، برای این منظور از رابطه ۱ استفاده شده است:

$$\eta_{i,j} = \frac{v_{i,j} - \min(V_j)}{\max(V_j) - \min(V_j)} \quad \text{رابطه ۱}$$

که V_j مجموعه مقادیر پارامتر λ و $v_{i,j} \in V_j$ که i شماره نمونه در مجموعه داده است. $\eta_{i,j}$ مقدار نرمال شده نمونه λ از پارامتر λ است.

کمینه افزونگی، بیشینه وابستگی (mRMR)

یکی از روش‌های انتخاب مجموعه ویژگی‌های مؤثر در پیش‌بینی مقدار پارامتر هدف، mRMR است. mRMR یک الگوریتم انتخاب ویژگی حداقل بهینه است. یعنی برای یافتن کوچک‌ترین زیرمجموعه ویژگی‌های مرتبط به یک پارامتر هدف طراحی شده است. بنابراین برای مسائل یادگیری ماشین بسیار مناسب می‌باشد زیرا انتخاب حداقل تعداد ویژگی‌های مفید بر عملکرد مدل‌های یادگیری ماشین، بسیار تأثیرگذار است. با روش mRMR ویژگی‌هایی انتخاب می‌شوند که حداکثر هم‌بستگی را با ویژگی هدف و حداقل هم‌بستگی را با دیگر ویژگی‌های انتخاب شده داشته باشند. برای ویژگی‌های پیوسته، می‌توان از آماره آزمون F برای محاسبه هم‌بستگی با پارامتر هدف که ارتباط (V) نامیده می‌شود، استفاده کرد و از ضریب هم‌بستگی پیرسون، برای محاسبه هم‌بستگی بین ویژگی‌های انتخاب شده که افزونگی (W) نامیده می‌شود، بهره برد. بنابراین تابع هدف، تابعی از ارتباط و افزونگی است که با رابطه ۲ محاسبه می‌شود:

$$\max \varphi(V, W), \varphi = V - W \quad \text{رابطه ۲}$$

که $\varphi(V, W)$ عملکردی برای ترکیب روابط بیشینه وابستگی و کمینه افزونگی است. با توجه به اینکه انتخاب فهرست بهترین ویژگی‌ها برای مجموعه داده‌ای با تعداد زیادی ویژگی، به دلیل نمایی بودن تعداد محاسبه‌های لازم برای یافتن حداکثر مقدار $\varphi(V, W)$ ، غیرعملی است. به همین دلیل روش‌هایی برای تخمین mRMR معرفی شده‌اند. از متداول‌ترین آن‌ها، می‌توان به روش تفاضل اطلاعات متقابل (MID) اشاره کرد. MID از طریق رابطه ۳ محاسبه می‌شود.

$$\max_{i \in \varphi(S)} [F(i, h) - \frac{1}{|S|} \sum_{j \in S} \text{corr}(i, j)] \quad \text{رابطه ۳}$$

$\text{corr}(i, j)$ ضریب هم‌بستگی بین دو ویژگی i و j است. S و h به ترتیب مجموعه ویژگی‌های انتخاب شده و پارامتر هدف هستند. $F(i, h)$ تابع محاسبه آماره آزمون F، بین ویژگی i با پارامتر هدف h است.

تجزیه و تحلیل مؤلفه‌های اصلی (PCA)

PCA یک الگوریتم یادگیری بدون نظارت است که برای کاهش ابعاد در یادگیری ماشین استفاده می‌شود. ابعاد بالا به این معناست که مجموعه داده، تعداد زیادی ویژگی دارد. مشکل اصلی مرتبط با ابعاد بالا در زمینه یادگیری ماشین، برآزش بیش از حد مدل است که توانایی تعمیم فراتر از نمونه‌های مجموعه آموزشی را کاهش می‌دهد. از این رو، با استفاده از الگوریتم PCA تلاش شده تا ابعاد مسئله به تعداد ابعاد کمتری تبدیل شود که اجزای اصلی در PCA نامیده می‌شوند. اجزای اصلی، همان ویژگی‌های جدید تغییر یافته یا خروجی PCA هستند. تعداد این ابعاد کمتر یا برابر ویژگی‌های اصلی موجود در مجموعه داده اولیه است. از مهم‌ترین خصوصیات اجزای اصلی این است که:

- هر جزء اصلی یک ترکیب خطی از ویژگی‌های اولیه است؛

- مؤلفه‌ها متعامدند؛ یعنی هم‌بستگی بین یک جفت متغیر صفر است؛
- اهمیت هر جزء از اجزای اصلی از جزء اول به سمت آخرین جزء کاهش می‌یابد.

مراحل الگوریتم PCA عبارت‌اند از:

۱. دریافت مجموعه داده: ابتدا مجموعه داده ورودی دریافت می‌شود.
۲. نمایش داده‌ها در یک ساختار: در این مرحله، مجموعه داده در یک ماتریس دو بعدی قرار می‌گیرد. هر سطر مربوط به یک نمونه از داده‌ها و هر ستون مربوط به مقادیر یک ویژگی است. تعداد ستون‌ها گویای ابعاد مجموعه داده است.
۳. استاندارد کردن داده‌ها: در یک ستون خاص، ویژگی‌های با واریانس بالا در مقایسه با ویژگی‌های با واریانس کمتر اهمیت بیشتری دارند. اگر اهمیت ویژگی‌ها، مستقل از واریانس ویژگی باشد، هر مورد داده در یک ستون، بر انحراف استاندارد ستون تقسیم می‌شود. ماتریس حاصل با Z نام‌گذاری می‌گردد.
۴. محاسبه کوواریانس Z : بدین منظور نیاز است که ترانهاده ماتریس Z در ماتریس Z ضرب شود.
۵. محاسبه مقادیر ویژه و بردارهای ویژه: بردارهای ویژه، جهت محورهای ماتریس کوواریانس با اطلاعات بالا هستند. همچنین، ضرایب این بردارهای ویژه به عنوان مقادیر ویژه تعریف می‌شوند.
۶. مرتب‌سازی بردارهای ویژه: در این مرحله تمام مقادیر ویژه دریافت و به ترتیب نزولی مرتب می‌شوند. هم‌زمان بردارهای ویژه را بر اساس نتایج مرتب‌سازی مقادیر ویژه، در ماتریس P مقادیر ویژه مرتب می‌شوند. ماتریس حاصل به صورت P^* نام‌گذاری می‌شود.
۷. محاسبه ویژگی‌های جدید یا اجزای اصلی: ماتریس P^* را در Z ضرب می‌شود. در ماتریس حاصل که Z^* نامیده شده است، هر مشاهده ترکیبی خطی از ویژگی‌های اصلی است. هر ستون از ماتریس Z^* مستقل از دیگر ستون‌هاست.
۸. حذف ویژگی‌های کم‌اهمیت یا بی‌اهمیت از مجموعه داده جدید: در این مرحله تنها ویژگی‌های مرتبط یا مهم در مجموعه داده جدید حفظ شده و ویژگی‌های غیر مهم حذف خواهند شد.

مدل‌های مورد استفاده برای پیش‌بینی شاخص بورس

برای انتخاب مدل مناسب برای پیش‌بینی شاخص بورس از دو مدل به نام‌های تابع پایه شعاعی و شبکه عصبی عمیق استفاده می‌شود. شایان ذکر است که هر دو مدل عملکرد بسیار خوبی را در تحقیقات مختلف نشان داده‌اند. در این ادامه، مدل‌های استفاده شده به صورت اجمالی معرفی می‌شوند.

تابع پایه شعاعی (RBF)

RBF یکی از انواع شبکه‌های عصبی است که بیشتر برای مسائل تخمین تابع استفاده می‌شود. این شبکه دارای ۳ لایه ورودی، پنهان و خروجی است. داده‌ها از طریق لایه ورودی به شبکه تزریق می‌شود. لایه دوم با نام لایه پنهان، شامل

نورون‌هایی است که از توابع پایه شعاعی برای پردازش اطلاعات ورودی استفاده می‌کند. نورون‌ها در لایه میانی، داده‌ها را از ورودی بدون تغییر دریافت می‌کنند. اغلب این نورون‌ها از تابع گوسی برای پردازش اطلاعات استفاده می‌کنند. این تابع با رابطه ۴ معرفی شده است.

$$h_i = \phi_i(X - \mu_i) = \exp\left(-\frac{\|X - \mu_i\|}{2\sigma_i^2}\right) \quad (\text{رابطه ۴})$$

X بردار ورودی (x_1, x_2, \dots, x_n) به شبکه عصبی است. i اندیس نورون را در لایه پنهان مشخص می‌کند. μ_i و σ_i به ترتیب مرکز و شعاع پذیرش نورون، یعنی ناحیه مرتبط با تابع را مشخص می‌کنند. حاصل توابع نورون‌های لایه مخفی، برای تنها نورون لایه خروجی ارسال می‌شود. نورون موجود در لایه خروجی، یک ترکیب خطی از توابع لایه پنهان ایجاد می‌کند. همان طور که در شکل مشاهده می‌شود، بین نورون‌های لایه پنهان و لایه خروجی از وزن اتصال استفاده می‌شود. مقادیر این وزن‌ها، به همراه مراکز و شعاع‌های نورون‌های لایه پنهان، در زمان آموزش مدل تعیین می‌شوند. نورون موجود در لایه خروجی با بهره‌گیری از رابطه ۵، مجموع وزن‌دار توابع گوسی لایه پنهان را محاسبه می‌کند.

$$y = \sum_{i=1}^k w_i h_i(X) \quad (\text{رابطه ۵})$$

y خروجی تنها نورون لایه خروجی شبکه است. w_i وزن اتصال نورون i ام لایه پنهان با نورون موجود در لایه خروجی است.

شبکه عصبی عمیق (DNN)

رگرسیون DNN به عنوان یکی از پرکاربردترین شبکه‌های عصبی با رویکرد یادگیری عمیق، در سال‌های اخیر مورد توجه محققان بوده است. این مدل شامل تعدادی لایه ورودی، پنهان و خروجی است. از مزیت‌های بهره‌گیری از این مدل، دقت بالای آن روی داده‌های پیچیده است (چونگ، هان و پارک، ۲۰۱۷).

از چالش‌های اصلی آن، وجود تئوری ضعیف ساختاری است. به بیان دیگر، تئوری خاصی برای چیدمان عناصر موجود در شبکه وجود ندارد. معمولاً به صورت تجربی و با تکنیک‌هایی مانند افزایش و کاهش تعداد لایه‌ها و نورون‌ها و انتخاب توابع فعالیت مختلف، به بررسی مدل پرداخته شده تا در نهایت دقت خوبی از مدل به دست آید. برای ایجاد مدل DNN مورد استفاده برای پیش‌بینی شاخص بورس از زبان برنامه‌نویسی پایتون و کتابخانه‌های موجود در این زبان استفاده شده است. بدین منظور از مدل‌های ترتیبی موجود در کتابخانه keras بهره گرفته شده است. شایان ذکر است که keras از کتابخانه‌های موجود در مجموعه tensorflow است و از آن به عنوان هسته استفاده می‌کند. لایه‌های مدل DNN با بهره‌گیری از توابع dense از کتابخانه‌های لایه keras ایجاد شده‌اند.

مدل پیشنهادی شامل ۵ لایه است: لایه اول به‌عنوان لایه ورودی برای دریافت مقادیر ورودی استفاده می‌شود. سپس، از سه لایه مخفی بهره گرفته شده است که به‌ترتیب شامل ۲۰، ۱۰ و ۵ نورون است. برای لایه‌های مخفی از تابع فعالیت ReLU استفاده می‌شود که از پُرکاربردترین و ساده‌ترین توابع فعال‌سازی غیرخطی است. دو مزیت این تابع آن است که با تعداد زیادی از متغیرهای پیش‌بینی اشباع نمی‌شود و خطاها به‌سادگی پس انتشار داده می‌شوند. آخرین لایه شبکه، لایه خروجی با یک نورون است که نتیجه پیش‌بینی شاخص بورس را برمی‌گرداند. در لایه خروجی از تابع فعالیت Sigmoid استفاده می‌شود. از دیگر تنظیمات انجام‌شده روی مدل، انتخاب مقدار دوره و اندازه دسته است. در مدل انتخابی، مقدار دوره و اندازه دسته به‌ترتیب ۱۰۰ و ۵ تعیین می‌شود. در یک دوره از همه نمونه‌های آموزش، برای به‌روزرسانی وزن‌های شبکه یک‌بار استفاده می‌شود. در آموزش دسته‌ای، قبل از به‌روزرسانی وزن‌ها، همه نمونه‌های آموزشی به‌طور هم‌زمان در یک دوره از الگوریتم آموزش استفاده می‌شوند. مدل پس از اتمام هر دوره و اندازه دسته به‌روز می‌شود. همچنین، برای محاسبه نرخ یادگیری تطبیقی برای هر پارامتر و به‌روزرسانی وزن‌های لایه مخفی از بهینه‌ساز Adam استفاده می‌شود.

معیارهای ارزیابی مدل‌های پیش‌بینی

در این مقاله، برای ارزیابی مدل‌ها در مرحله پیاده‌سازی از روش اعتبارسنجی متقابل K-fold^۱ استفاده شده است. در این روش، مجموعه داده‌ها به ۱۰ دسته متمایز تقسیم می‌شوند. در هر مرحله، ۹ دسته برای آموزش مدل و یک دسته برای آزمایش مدل انتخاب می‌شوند. شایان ذکر است که پیش از تقسیم‌بندی داده‌ها، ابتدا جایگشتی روی مجموعه داده‌ها انجام شده تا نمونه‌ها به‌هم‌ریخته شوند. این به‌هم‌ریختگی باعث تنوع نمونه‌ها در توزیع داده‌ها می‌شود.

برای بررسی دقت مدل‌های پیش‌بینی، از معیارهای میانگین قدر مطلق خطا (MAE)^۲، میانگین مربع خطا (MSE)^۳ و ریشه میانگین مربع خطا (RMSE)^۴ استفاده شده است که از طریق رابطه‌های ۶، ۷ و ۸ محاسبه می‌شود.

$$MAE = \frac{1}{N} \sum_{i=1}^N |t_i - y_i| \quad \text{رابطه ۶}$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad \text{رابطه ۷}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2} \quad \text{رابطه ۸}$$

1. K-fold Cross Validation
2. Mean Absolute Error
3. Mean Square Error
4. Root Mean Square Error

N تعداد نمونه‌ها، t_i مقدار هدف و y_i مقدار پیش‌بینی شده برای نمونه i ام است.

یافته‌های پژوهش

انتخاب مدل مناسب برای پیش‌بینی بازده شاخص کل بورس اوراق بهادار

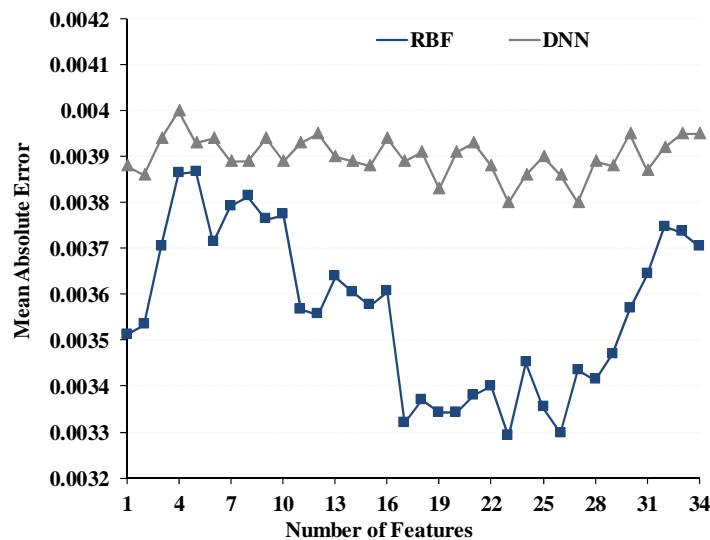
برای انتخاب مدل مناسب پیش‌بینی روزانه شاخص بورس، به مقایسه دو مدل هوشمند، به نام‌های شبکه عصبی تابع پایه شعاعی (RBF) و شبکه عصبی عمیق (DNN)، پرداخته می‌شود. برای این منظور ابتدا به اولویت‌بندی ویژگی‌ها با استفاده از روش تفاضل اطلاعات متقابل (MID) که یکی از روش‌های تخمین کمینه افزونگی، بیشینه وابستگی (mRMR) است، اقدام می‌شود.

جدول ۲. اولویت‌بندی ویژگی‌ها با الگوریتم MID با توجه به شاخص بورس یک روز آینده

شماره	نام ویژگی	شماره	نام ویژگی
۱	تفاوت نسبی درصد بازده شاخص در ۵ روز گذشته	۲	تغییر نسبی حجم معاملات در ۱ روز گذشته
۳	میانگین متحرک نمای قیمت پایانی ۲۰ روز گذشته	۴	بازده شاخص کل بورس در ۱ روز گذشته
۵	تغییر قیمت سکه طلا در ۳ روز گذشته	۶	تغییر قیمت نفت اوپک در ۳ روز گذشته
۷	تفاوت نسبی درصد بازده شاخص در ۱۵ روز گذشته	۸	تغییر نسبی حجم معاملات در ۲ روز گذشته
۹	تغییر قیمت نفت اوپک در ۲ روز گذشته	۱۰	تغییر نرخ دلار در ۳ روز گذشته
۱۱	بازده شاخص ۳۰ شرکت بزرگ در سه روز گذشته	۱۲	تفاوت نسبی درصد بازده شاخص در ۱۰ روز گذشته
۱۳	تغییر نرخ دلار در ۱ روز گذشته	۱۴	تغییر نسبی حجم معاملات در ۳ روز گذشته
۱۵	بازده شاخص ۳۰ شرکت بزرگ در ۱ روز گذشته	۱۶	تغییر قیمت سکه طلا در ۱ روز گذشته
۱۷	بازده شاخص ۳۰ شرکت بزرگ در ۲ روز گذشته	۱۸	تغییر قیمت نفت اوپک در ۱ روز گذشته
۱۹	تغییر نرخ دلار در ۲ روز گذشته	۲۰	تفاوت نسبی درصد بازده شاخص در ۲۰ روز گذشته
۲۱	تغییر قیمت سکه طلا در ۲ روز گذشته	۲۲	بازده شاخص ۵۰ شرکت فعال بورس در ۱ روز گذشته
۲۳	بازده شاخص کل بورس در ۳ روز گذشته	۲۴	شاخص سطح مقاومت قیمت برای ۱۲۰ روز گذشته
۲۵	بازده شاخص کل بورس در ۲ روز گذشته	۲۶	بازده شاخص ۵۰ شرکت فعال بورس در ۳ روز گذشته
۲۷	میانگین متحرک نمای قیمت پایانی ۵۰ روز گذشته	۲۸	بازده شاخص ۵۰ شرکت فعال بورس در ۲ روز گذشته
۲۹	شاخص سطح مقاومت قیمت برای ۳۰ روز گذشته	۳۰	میانگین متحرک قیمت پایانی ۱۰ روز گذشته
۳۱	میانگین متحرک نمای قیمت پایانی ۲۰۰ روز گذشته	۳۲	میانگین متحرک قیمت پایانی ۳۰ روز گذشته
۳۳	میانگین متحرک قیمت پایانی ۵ روز گذشته	۳۴	میانگین متحرک نمای قیمت پایانی ۱۰ روز گذشته

از مزیت‌های استفاده از MID پایین بودن پیچیدگی محاسباتی آن است. در واقع، سربار پایین، سرعت و قابلیت اطمینان بالا، باعث استفاده از این روش آماری شده است. بنابراین ویژگی‌های موجود در مجموعه داده ورودی را با استفاده از

الگوریتم MID در بردار ζ براساس حداکثر وابستگی ویژگی‌ها با مقدار خروجی و حداقل هم‌بستگی بین ویژگی‌های ورودی با یکدیگر، اولویت‌بندی می‌شوند. سپس در $|\zeta|$ گام، زیرمجموعه‌هایی شامل $|\zeta| \leq z \leq 1$ عنصر ابتدایی از ζ را در دو مدل RBF و DNN ارزیابی کرده و میزان خطای پیش‌بینی برای هر یک اندازه‌گیری می‌گردد. ترتیب اولویت ویژگی‌ها با بهره‌گیری از MID در جدول ۲ نمایش داده شده است. همچنین نتایج استفاده از الگوریتم MID در اولویت‌بندی داده‌ها در دو مدل مورد بررسی در شکل ۲ نمایش داده شده است. شایان ذکر است که به‌منظور تقسیم داده‌ها در دو دسته آموزش و آزمایش از روش اعتبارسنجی متقابل K-fold استفاده می‌گردد. با بهره‌گیری از شکل ۲ می‌توان به این نتیجه رسید که در مدل DNN افزایش تعداد ویژگی‌ها منجر به بهبود مدل نشده، و کمترین خطا در استفاده از مدل RBF با ۲۳ ویژگی حاصل شده است. بنابراین مدل RBF به‌عنوان مدل مناسب برای پیش‌بینی روزانه شاخص کل بورس اوراق بهادار تهران انتخاب می‌شود.



شکل ۲. مقایسه استفاده از مدل‌های RBF و DNN در پیش‌بینی شاخص بورس

انتخاب ویژگی‌های مناسب برای پیش‌بینی شاخص کل بورس اوراق بهادار تهران

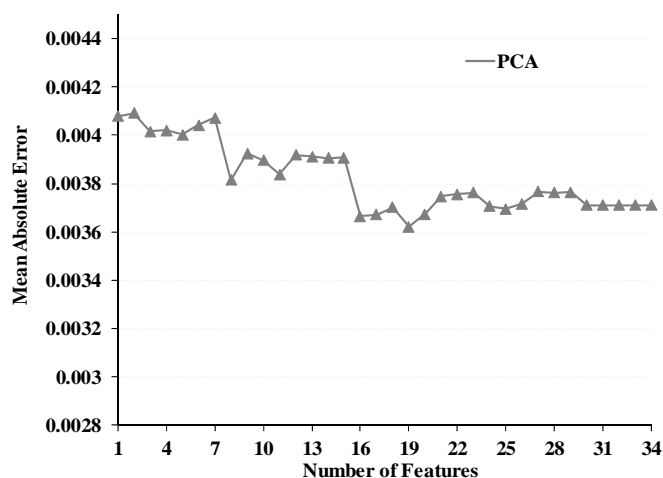
همان‌طور که در شکل ۲ مشخص شد، مدل RBF با تعداد ۲۳ ویژگی بهترین دقت را در پیش‌بینی شاخص بورس داشته است. یکی از نکات شایان توجه این است که چهار ویژگی ۶، ۱۱، ۱۷ و ۲۳ یعنی تغییر قیمت نفت اوپک در ۳ روز گذشته، بازده شاخص ۳۰ شرکت بزرگ در سه روز گذشته، بازده شاخص ۳۰ شرکت بزرگ در ۲ روز گذشته و بازده شاخص کل بورس در سه روز گذشته، تأثیر چشمگیری در بهبود عملکرد مدل RBF داشته‌اند. نتایج در جدول ۳ نشان شده است.

جدول ۳. تأثیر چهار ویژگی بر عملکرد مدل RBF

شماره ویژگی	نام ویژگی	MAE	MSE	RMSE	درصد خطا
شماره ۶	تغییر قیمت نفت اوپک در ۳ روز گذشته	۰/۰۰۳۷۱۳	۰/۰۰۰۰۳۶	۰/۰۰۶۰۵	۱۳/۸۸
شماره ۱۱	بازده شاخص ۳۰ شرکت بزرگ در سه روز گذشته	۰/۰۰۳۵۶۷	۰/۰۰۰۰۳۱	۰/۰۰۵۶۳۷	۱۳/۷۴
شماره ۱۷	بازده شاخص ۳۰ شرکت بزرگ در ۲ روز گذشته	۰/۰۰۳۳۲	۰/۰۰۰۰۲۷	۰/۰۰۵۱۶۴	۱۳/۵۲
شماره ۲۳	بازده شاخص کل بورس در سه روز گذشته	۰/۰۰۳۲۹۱	۰/۰۰۰۰۲۷	۰/۰۰۵۲۰۲	۱۳/۳۳

استخراج ویژگی‌های مناسب برای پیش‌بینی شاخص کل بورس اوراق بهادار تهران

در این پژوهش، با استفاده از تحلیل مؤلفه‌های اصلی (PCA)، ویژگی‌های مؤثر برای مدل پیش‌بینی شاخص بورس استخراج می‌شود؛ به طوری که با توجه به تعداد ابعاد خروجی در نظر گرفته شده برای PCA، استخراج ویژگی‌ها انجام می‌شود. نتایج در شکل ۳ نشان داده شده است. با توجه به نتایج مشاهده می‌شود که با افزایش تعداد ابعاد PCA تا ۱۹ بُعد، دقت مدل پیش‌بینی افزایش می‌یابد و بعد از آن تغییر تعداد ابعاد ویژگی‌ها بهبودی در دقت مدل ایجاد نمی‌کند. نتایج در جدول ۴ ارائه شده است.



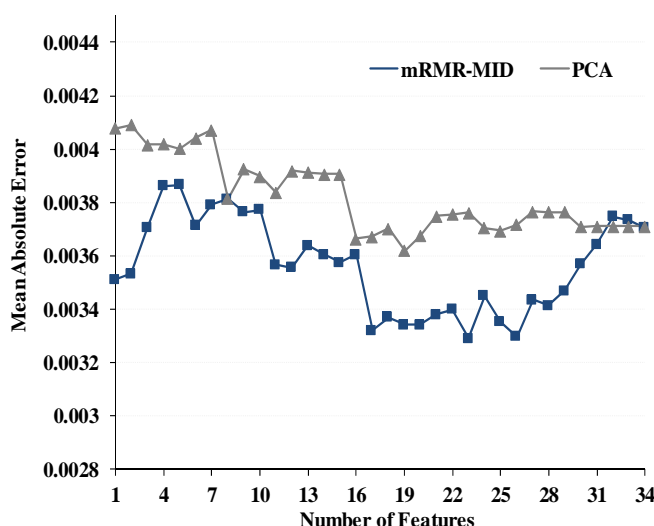
شکل ۳. استفاده از PCA به منظور استخراج ویژگی‌های مدل RBF برای پیش‌بینی شاخص بورس

جدول ۴. نتایج استخراج ویژگی با PCA در مدل RBF

تعداد ابعاد	MAE	MSE	RMSE	درصد خطا
۱۹ بُعد ویژگی	۰/۰۰۳۶	۰/۰۰۰۰۳۲	۰/۰۰۵۶	۱۳/۷۶

برای اینکه بتوان راحت‌تر عملکرد دو تکنیک کاهش ابعاد (انتخاب و استخراج ویژگی) را در دقت مدل RBF مقایسه کرد، نتیجه بهره‌گیری از هر دو تکنیک کاهش ابعاد، در شکل ۴ نمایش داده شده است. در این شکل، دقت بیشتر

استفاده از روش انتخاب ویژگی‌ها نسبت به استخراج ویژگی‌ها مشهود است. با مقایسه دو منحنی در شکل ۴، می‌توان به این نتیجه رسید که بدون استفاده از PCA، دقت حاصل‌شده از مدل RBF بهتر است. بر این اساس، به استخراج ویژگی برای پیش‌بینی شاخص بورس نیازی نیست و باید تمرکز روی انتخاب ویژگی‌های مناسب برای آن باشد.



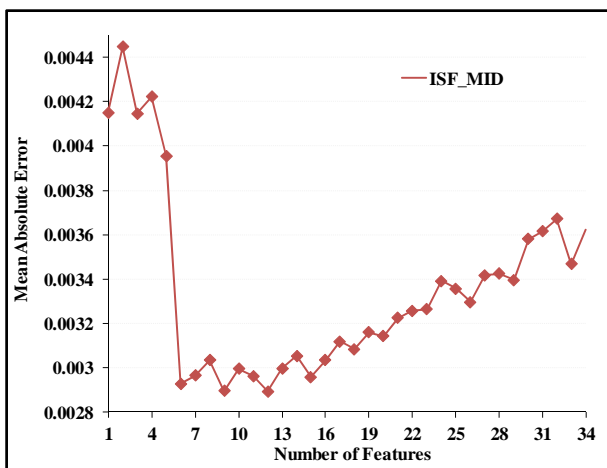
شکل ۴. استفاده از دو تکنیک کاهش ابعاد برای پیش‌بینی شاخص بورس با بهره‌گیری از مدل RBF

رویکرد پیشنهادی در انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی شاخص بورس

در این مطالعه، برای انتخاب ویژگی‌های مناسب، مدل پیش‌بینی شاخص بورس روشی پیشنهاد شده است که در این روش، تعدادی از ویژگی‌ها را محقق انتخاب می‌کند. همان‌طور که پیش از این اشاره شد، چهار ویژگی به نام‌های تغییر قیمت نفت اوپک در ۳ روز گذشته، بازده شاخص ۳۰ شرکت بزرگ در سه روز گذشته، بازده شاخص ۳۰ شرکت بزرگ در ۲ روز گذشته، و بازده شاخص کل بورس در سه روز گذشته، تأثیر چشمگیری در کاهش خطای پیش‌بینی مدل RBF داشته‌اند. بر این اساس، تصمیم بر آن شد که برای اولویت‌بندی ویژگی‌ها در الگوریتم پیشنهادی، ابتدا این چهار ویژگی را به‌عنوان ویژگی‌های معرفی شده، انتخاب کرده و سپس سایر ویژگی‌ها با الگوریتم MID اولویت‌بندی شوند. این الگوریتم تحت عنوان ویژگی‌های انتخابی اولیه - تفاضل اطلاعات متقابل (ISF_MID) ^۱، در این پژوهش معرفی می‌شود. ویژگی‌ها با اولویت جدیدی که برای آن‌ها به‌دست آمده است، به‌ترتیب به مدل RBF به‌منظور پیش‌بینی بازده شاخص بورس داده می‌شوند. شایان ذکر است که در این ارزیابی نیز از روش اعتبارسنجی متقابل K-fold استفاده می‌شود. نتایج به‌دست آمده با الگوریتم پیشنهادی ISF_MID در شکل ۵ نشان داده شده است. نتایج نشان می‌دهد که مدل RBF با ویژگی‌های انتخابی توسط الگوریتم ISF_MID، تنها با ۶ ویژگی، بهترین نتیجه را ارائه کرده است. نتایج در جدول ۵ ارائه شده است. این ویژگی‌ها به‌ترتیب عبارت‌اند از: تغییر قیمت نفت اوپک در ۳ روز گذشته، بازده شاخص ۳۰ شرکت

1. Selected Features_Mutual Information Difference

بزرگ در سه روز گذشته، بازده شاخص ۳۰ شرکت بزرگ در ۲ روز گذشته، بازده شاخص کل بورس در سه روز گذشته، بازده شاخص کل بورس در ۱ روز گذشته، و تفاوت نسبی در درصد بازده شاخص در ۵ روز گذشته.

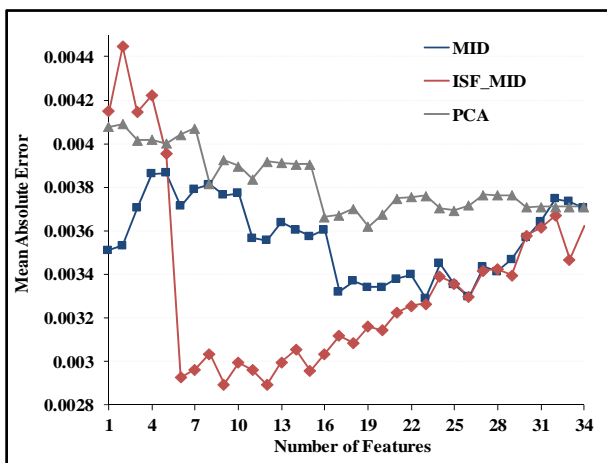


شکل ۵. استفاده از الگوریتم ISF_MID به منظور انتخاب ویژگی‌های مدل RBF برای پیش‌بینی شاخص بورس

جدول ۵. نتایج انتخاب ویژگی با الگوریتم ISF_MID در مدل RBF

تعداد ابعاد	MAE	MSE	RMSE	درصد خطا
۶ ویژگی	۰/۰۰۲۹	۰/۰۰۰۰۲۱	۰/۰۰۴۶	۱۲/۴۶

در نهایت، به منظور سهولت مقایسه سه روش ارائه شده در این پژوهش، نتایج استخراج ویژگی‌ها با الگوریتم PCA و انتخاب ویژگی‌ها با الگوریتم MID و ISF_MID در شکل ۶ مجدد ارائه می‌شود. با مقایسه نمودارهای موجود در شکل ۶ می‌توان مشاهده کرد که مدل RBF با ویژگی‌های انتخابی توسط الگوریتم ISF_MID، بیشترین دقت را ارائه کرده است. بنابراین می‌توان نتیجه گرفت که روش ارائه شده در این پژوهش جهت انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی شاخص بورس، نسبت به سایر روش‌های معمول انتخاب ویژگی، عملکرد بهتری را ارائه می‌کند.



شکل ۶. مقایسه استفاده از MID، PCA و ISF-MID در انتخاب ورودی‌های مدل RBF برای پیش‌بینی شاخص بورس

نتیجه‌گیری و پیشنهادها

پیش‌بینی شاخص بورس یک موضوع مهم تحقیقاتی است و به دلیل مزایای مالی بالقوه آن، توجه بسیاری را به خود جلب کرده است. در این پژوهش، به منظور انتخاب مدل مناسب برای پیش‌بینی شاخص بورس، دو مدل RBF و DNN که به ترتیب از مهم‌ترین و بدیع‌ترین مدل‌های پیش‌بینی هستند، با یکدیگر مقایسه شدند و از میان آن‌ها RBF که عملکرد بهتری در پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران داشت، انتخاب شد. این نتیجه با یافته‌های پژوهش‌های تهرانی، حیرانی و منصور (۱۳۹۸) و حقیقت منفرد، احمدعلی‌نژاد و متقالجی (۱۳۹۱) و گوئرسن و همکاران (۲۰۱۱)، مطابقت دارد. از آنجایی که پیش‌بینی دقیق حرکات قیمت سهام تا حد زیادی به انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی بستگی دارد، به منظور انتخاب ویژگی‌های مناسب برای ورودی مدل RBF، الگوریتمی به نام JSF_MID، پیشنهاد شد که باعث افزایش دقت مدل پژوهش گردید. برای شناسایی این الگوریتم ابتدا از هر دو تکنیک کاهش ابعاد (انتخاب و استخراج ویژگی) برای داده‌کاوی و پیش‌پردازش داده‌های ورودی به مدل RBF استفاده شد تا تأثیر هر دو روش کاهش ابعاد در دقت عملکرد مدل RBF شناسایی شود؛ به طوری که برای استخراج ویژگی‌های مناسب نظیر مطالعات چن، ژانگ و لو (۲۰۲۰)، سینگ و سریواستاوا (۲۰۱۷)، ژونگ و انکه (۲۰۱۷)، تقوی و همکاران (۱۳۹۹) و راعی، نیک‌عهد و حبیبی (۱۳۹۵)، از PCA و برای انتخاب ویژگی‌های مناسب مشابه پژوهش گوندوز و کتلپه (۲۰۱۵)، از MID استفاده گردید.

در روش MID مشابه پژوهش افشاری راد، علوی و سینایی (۱۳۹۷)، ویژگی‌ها اولویت‌بندی می‌شوند. این روش در انتخاب ویژگی‌های مناسب مدل پیش‌بینی، نه تنها به هم‌بستگی ویژگی‌های ورودی نسبت به خروجی مدل توجه می‌کند، بلکه وابستگی بین ویژگی‌های ورودی با یکدیگر را نیز بررسی کرده که این امر باعث می‌شود احتمال انتخاب زیرمجموعه‌ای با افزونگی از بین رود. همچنین برخلاف الگوریتم‌های فرااکتشافی^۱ مورد استفاده پژوهش‌های صورت گرفته پیشین مانند نیکوسخن (۱۳۹۷)، آسیما و عباس‌زاده اصل (۱۳۹۸) و عبادتی و مرتضوی (۲۰۱۶) که یک زیرمجموعه از مجموعه کل ویژگی‌ها که مقدار خطای کمتری نسبت به دیگر زیرمجموعه‌های بررسی شده دارد، ارائه می‌دهند که آن زیرمجموعه، ممکن است یک بهینه محلی برای مسائل بهینه‌سازی باشد، روش MID سعی در ایجاد یک راه‌حل بهینه در سطح سراسری می‌کند.

در نهایت با مقایسه عملکرد دو نوع تکنیک کاهش ابعاد، مشخص شد که الگوریتم MID نسبت به الگوریتم PCA در انتخاب متغیرهای ورودی مدل RBF نتیجه بهتری را ارائه کرده است. بنابراین با توجه به اولویت‌بندی ویژگی‌ها با الگوریتم MID و الگوی تغییر مقدار خطا با افزایش تعداد ویژگی‌ها در مدل RBF، الگوریتم JSF_MID، برای انتخاب ویژگی‌های مناسب مدل پیش‌بینی شاخص بورس پیشنهاد شد. با این الگوریتم می‌توان با کمترین تعداد ویژگی، بیشترین دقت را در پیش‌بینی شاخص بورس به دست آورد. شایان ذکر است که در این مطالعه، برای ارزیابی مدل در مرحله پیاده‌سازی، مشابه پژوهش‌های سیف، جمشیدی نوید، قنبری و اسماعیل پور (۱۴۰۰)، بوستوس، پومارس و

گونزالس^۱ (۲۰۱۸) و ناهیل و لیحیایی^۲ (۲۰۱۸)، از روش اعتبارسنجی متقابل K-fold استفاده شد. با این روش همه داده‌ها یک‌بار برای آموزش و یک‌بار برای آزمایش مورد استفاده قرار گرفته که این امر باعث بهبود تعمیم نتایج مدل پیش‌بینی می‌گردد.

بنابراین در این پژوهش تلاش شده است که چالش‌ها و معایب روش‌های گذشته برای پیش‌بینی شاخص بورس تا حد زیادی برطرف شود و برای انتخاب ویژگی‌های مناسب مدل پیش‌بینی شاخص بورس روشی پیشنهاد شود که نسبت به سایر روش‌های ارائه شده در این حوزه، باعث بهبود چشمگیری در دقت مدل پیش‌بینی و همچنین کاهش بار محاسباتی می‌گردد. در پایان با توجه به سادگی و اثربخشی رویکرد ارائه شده در این مقاله، پیشنهاد می‌شود پژوهشگران حوزه‌های مختلف مدل‌سازی جهت انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی، این رویکرد را نیز در مطالعات خود مورد بررسی و استفاده قرار دهند.

منابع

- آسیما، مهدی؛ علی عباس زاده اصل، امیر (۱۳۹۸). ارائه مدل ترکیبی برآورد بازده مورد انتظار با استفاده از الگوریتم ژنتیک. *تحقیقات مالی*، ۲۱(۱)، ۱۰۱-۱۲۰.
- افشاری راد، الهام؛ علوی، سیدعنایت اله؛ سینایی، حسنعلی (۱۳۹۷). مدلی هوشمند برای پیش‌بینی روند سهام با استفاده از روش‌های تحلیل تکنیکال. *تحقیقات مالی*، ۲۰(۲)، ۲۴۹-۲۶۴.
- پشوتنی‌زاده، هومن؛ رعنائی کردشولی، حبیب‌الله؛ عباسی، عباس؛ موسوی حقیقی، محمد هاشم (۱۳۹۹). شبیه‌سازی الگوی تأثیرات عوامل رفتاری و کلان اقتصادی بر شاخص کل بورس اوراق بهادار تهران با استفاده از رویکرد پویایی‌شناسی سیستمی. *چشم‌انداز مدیریت مالی*، ۱۰(۲۹)، ۸۹-۱۲۴.
- تقوی، رضا؛ داداشی، ایمان؛ زارع بهنمیری، محمد جواد؛ غلام‌نیا روشن، حمید رضا (۱۳۹۹). پیش‌بینی گرایش احساسی سرمایه‌گذاران با استفاده از تکنیک‌های ماشین بردار پشتیبان (SVM) و درخت تصمیم (DT). *مهندسی مالی و مدیریت اوراق بهادار*، ۱۱(۴۵)، ۵۴۴-۵۷۰.
- تهرانی، رضا؛ حیرانی، میلاد؛ منصوری، سمیرا (۱۳۹۸). مقایسه عملکرد مدل پنج عاملی فاما و فرنچ و انواع رویکردهای شبکه عصبی و عصبی فازی در پیش‌بینی قیمت سهام. *مهندسی مالی و مدیریت اوراق بهادار*، ۱۰(۳۹)، ۲۷۸-۲۹۴.
- حقیقت منفرد، جلال؛ احمدعلی‌نژاد، محمود؛ متقالچی، سارا (۱۳۹۱). مقایسه مدل‌های شبکه عصبی با مدل سری زمانی باکس - جنکینز در پیش‌بینی شاخص کل قیمت سهام بورس اوراق بهادار تهران. *مهندسی مالی و مدیریت اوراق بهادار*، ۳(۱۱)، ۱-۱۶.

- ذوالفقاری، مهدی؛ سحابی، بهرام؛ بختیاران، محمد جواد (۱۳۹۹). طراحی مدلی جهت پیش‌بینی بازده شاخص کل بورس اوراق بهادار (با تأکید بر مدل‌های ترکیبی شبکه یادگیری عمیق و مدل‌های خانواده GARCH). *مهندسی مالی و مدیریت اوراق بهادار*، ۱۱(۴۲)، ۱۳۸-۱۷۱.
- راعی، رضا؛ نیک عهد، علی؛ حبیبی، مصطفی (۱۳۹۵). پیش‌بینی شاخص بورس اوراق بهادار تهران با ترکیب روش‌های آنالیز مؤلفه‌های اصلی، رگرسیون بردار پشتیبان و حرکت تجمعی ذرات. *راهبرد مدیریت مالی*، ۴(۱۵)، ۱-۲۳.
- سیف، سمیرا؛ جمشیدی نوید، بابک؛ قنبری، مهرداد؛ اسماعیل پور، منصور (۱۴۰۰). پیش‌بینی روند بورس سهام ایران با استفاده از نوسان نمای موج الیوت و شاخص قدرت نسبی. *تحقیقات مالی*، ۲۳(۱)، ۱۳۴-۱۵۷.
- صالحی، مجتبی؛ گرشاسبی، فاطمه (۱۳۹۸). پیش‌بینی شاخص کل بورس اوراق بهادار تهران با رویکرد سیستم استنتاج عصبی - فازی انطباق پذیر و الگوریتم رقابت استعماری. *مطالعات مدیریت کسب و کار هوشمند*، ۸(۲۹)، ۵-۳۴.
- فقیهی‌نژاد، محمد تقی؛ مینایی، بهروز (۱۳۹۷). پیش‌بینی رفتار بازار سهام بر اساس شبکه‌های عصبی مصنوعی با رویکرد یادگیری جمعی هوشمند. *مدیریت صنعتی*، ۱۰(۲)، ۳۱۵-۳۳۴.
- نیکوسخن، معین (۱۳۹۷). ارائه یک مدل ترکیبی بهبودیافته با انتخاب وقفه‌های خودکار برای پیش‌بینی بازار سهام. *تحقیقات مالی*، ۲۰(۳)، ۳۸۹-۴۰۸.

References

- Afshari Rad, E., Alavi, S. & Sinaei, H. (2018). Developing an Intelligent Model to Predict Stock Trend Using the Technical Analysis. *Financial Research Journal*, 20(2), 249-264. (in Persian)
- Asima, M., Ali Abbaszadeh Asl, A. (2019). Developing a Hybrid Model to Estimate Expected Return Based on Genetic Algorithm. *Financial Research Journal*, 21(1), 101-120. (in Persian)
- Atsalakis, G. S. & Valavanis, K. P. (2009). Surveying stock market forecasting techniques-Part II: Soft computing methods. *Expert Systems with Applications*, 36 (3), 5932-5941.
- Bengio, Y., Courville, A. & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35 (8), 1798-1828.
- Bustos, O., Pomares, A. & Gonzalez, E. (2018). A comparison between SVM and multilayer perceptron in predicting an emerging financial market: Colombian stock market. In *2017 Congreso Internacional de Innovación y Tendencias en Ingeniería, CONIITI 2017-Conference Proceedings*, Institute of Electrical and Electronics Engineers Inc, January, 1-6.
- 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.

- Cervelló-Royo, R. & Guijarro, F. (2020). Forecasting stock market trend: A comparison of machine learning algorithms. *Finance, Markets and Valuation*, 6(1), 37–49.
- Chen, Q., Zhang, W. & Lou, Y. (2020). Forecasting stock prices using a hybrid deep learning model integrating attention mechanism, multi-layer perceptron, and bidirectional long-short term memory neural network, *IEEE Access*, 8, 117365-117376.
- Cheng, C. H. & Wei, L. Y. (2014). A novel time-series model based on empirical mode decomposition for forecasting TAIEX. *Economic Modelling*, 36: 136–141.
- Chong, E., Han, C. & Park, F. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83: 187–205.
- Dash, R. & Dash, P. (2016). A comparative study of radial basis function network with different basis functions for stock trend prediction, In *2015 IEEE Power, Communication and Information Technology Conference, (PCITC 2015)*, Institute of Electrical and Electronics Engineers Inc. 430-435.
- Ding, X., Zhang, Y., Liu, T. & Duan, J. (2015). Deep learning for event-driven stock prediction. In *Proceedings of the 24th International Conference on Artificial Intelligence: 2327-2333*. AAAI Press.
- Ebadati, O. M. & Mortazavi, M. (2016). An efficient hybrid machine learning method for time series stock market forecasting. *Neural Network World*, 28(1), 41-55.
- Faghihi Nezhad, M. & Minaei, 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)
- Gunduz, H. & Cataltepe, Z. (2015). Borsa Istanbul (BIST) daily prediction using financial news and balanced feature selection. *Expert Systems with Applications*, 42 (22), 9001-9011.
- Gündüz, H., Çataltepe, Z. & Yaslan, Y. (2017). Stock daily return prediction using expanded features and feature selection. *Turkish Journal of Electrical Engineering & Computer Sciences*, 25(6), 4829-4840.
- Guo, Z., Ye, W., Yang, J. & Zeng, Y. (2017). Financial index time series prediction based on bidirectional two dimensional locality preserving projection, In *2017 IEEE 2nd International Conference on Big Data Analysis*, Institute of Electrical and Electronics Engineers Inc, 934-938.
- Guresen, E., Kayakutlu, G. & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert systems with application*, 38, 10389-10397.
- Henrique, B. M., Sobreiro, V. A. & Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124: 226-251.
- Hinton, G. E. & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504-507.
- Hinton, G. E., Osindero, S. & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.

- Hu, H., Tang, L., Zhang, S. & Wang, H. (2018). Predicting the direction of stock markets using optimized neural networks with google trends. *Neurocomputing*, 285, 188-195.
- Huang, C. L. & Tsai, C. Y. (2009). A hybrid SOFM-SVR with a filter-based feature selection for stock market forecasting. *Expert Systems with Applications*, 36 (2), 1529-1539.
- Kimoto, T., Asakawa, K., Yoda, M. & Takeoka, M. (1990). Stock market prediction system with modular neural network, in *International Joint Conference on Neural Networks*, 1-6.
- Kuremoto, T., Kimura, S., Kobayashi, K. & Obayashi, M. (2014). Time series forecasting using a deep belief network with restricted Boltzmann machines. *Neurocomputing*, 137: 47-56.
- Le Roux, N. & Bengio, Y. (2008). Representational power of restricted Boltzmann machines and deep belief networks. *Neural Computation*, 20 (6), 1631-1649.
- Lee, H., Grosse, R., Ranganath, R. & Ng, A. Y. (2009). Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. In *Proceedings of the 26th annual international conference on machine learning*, Montreal, Canada: 609-616.
- Lee, M. C. (2009). Using support vector machine with a hybrid feature selection method to the stock trend prediction. *Expert Systems with Applications*, 36 (8):10896–10904.
- Lin, Y., Guo, H., & Hu, J. (2013). An svm-based approach for stock market trend prediction. In *The 2013 international joint conference on neural networks (IJCNN)*, IEEE. 1-7
- Long, W., Lu, Z. & Cui, L. (2019). Deep learning-based feature engineering for stock price movement prediction. *Knowledge-Based Systems*, 164, 163-173.
- Monfared, J., Alinejad, M. & Metghalchi, S. (2012). A Comparative Study of Neural Network Models With Box Jenkins Methodologies in Prediction of Tehran Price Index(TEPIX). *Financial Engineering and Securities management (Portfolio Management)*, 3(11), 1-16. (in Persian)
- Nahil, A. & Lyhyaoui, A. (2018). Short-term stock price forecasting using kernel principal component analysis and support vector machines: the case of Casablanca stock exchange. *Procedia Computer Science*, 127, 161-169.
- Nelson, M. & Illingworth, W. (1991). *A Practical Guide to Neural Nets*, Boston, MA: Addison-Wesley Publishing Company.
- Niku sokhan, M. (2018). An Improved Hybrid Model with Automated Lag Selection to Forecast Stock Market. *Financial Research Journal*, 20(3), 389-408. (in Persian)
- Pashootanizadeh, H., Ranaei Kordshouli, H., Abbasi, A. & Moosavi haghghi, M. (2020). Simulation the Model of Effects of Behavioral and Macroeconomic Factors on the Tehran Stock Exchange Index with Using System Dynamics Approach. *Journal of Financial Management Perspective*, 10(29), 89-124. (in Persian)
- Pearson, K. (1901). On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, 2(6), 559-572.
- Qiu, M., and Y. Song. (2016). Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model. *PLoS ONE*, 11(5), 1-11.

- Raee, R., Nikahd, A. & Habibi, M. (2017). The Index Prediction of Tehran Stock Exchange by Combining the Principal Components Analysis, Support Vector Regression and Particle Swarm Optimization. *Financial Management Strategy*, 4(15), 1-23. (in Persian)
- Salehi, M. & Garshasbi, F. (2019). Tehran Stock Exchange Index Forecasting Using Approach Adaptive Neural-Fuzzy Inference System and Imperialist Competitive Algorithm. *IT Management Studies*, 8(29), 5-34. (in Persian)
- Seif, S., Jamshidi navid, B., Ghanbari, M. & Esmail pour, M. (2021). Predicting Stock Market Trends of Iran Using Elliott Wave Oscillation and Relative Strength Index. *Financial Research Journal*, 23(1), 134-157. (in Persian)
- Sezer, O. B., Gudelek, M. U. & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 1-63.
- Singh, R. & Srivastava, S. (2017). Stock prediction using deep learning. *Multimedia Tools and Applications*, 76(18), 18569-18584.
- Taghavi, R., Dadashi, I., Zare bahnamiri, M. & Gholamnia roshan, H. (2020). Predicting Emotional Tendency of Investors Using Support Vector Machine (SVM) and Decision Tree (DT) Techniques. *Financial engineering portfolio securities management*, 11(45), 544-570. (in Persian)
- Tehrani, R., Heyrani, M. & Mansuri, S. (2019). A Comparison between Fama and French five-factor model and artificial neural networks in predicting the stock price. *Financial Engineering and Securities management (Portfolio Management)*, 10(39), 278-294. (in Persian)
- Ul Haq, A., Zeb, A., Lei, Z. & Zhang, D. (2021). Forecasting daily stock trend using multi-filter feature selection and deep learning. *Expert Systems with Applications*, 168(3), 1-8.
- Yoo, P., Kim, M. & Jan, T. (2005). Machine learning techniques and use of event information for stock market prediction: A survey and evaluation. In *Proceedings - International Conference on Computational Intelligence for Modeling, Control and Automation, (CIMCA 2005)*. Piscataway, NJ: IEEE, 835-841.
- Zhang, X. L. & Wu, J. (2013). Deep belief networks based voice activity detection. *IEEE Transactions on Audio, Speech, and Language Processing*, 21 (4), 697-710.
- Zhong, X. & Enke, D. (2017). A comprehensive cluster and classification mining procedure for daily stock market return forecasting. *Neurocomputing*, 267, 152–168.
- Zhong, X. & Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1), 1-20.
- Zolfaghari, M., Sahabi, B. & Bakhtyaran, M. (2020). Designing a Model for Forecasting the Stock Exchange Total Index Returns (Emphasizing on Combined Deep Learning Network Models and GARCH Family Models). *Financial Engineering and Securities management (Portfolio Management)*, 11(42), 138-171. (in Persian)