

Prediction of the Stock Market Index with the Help of Visibility Graph¹

Mohammad Osoolian², Neda Mobayen³, Seyed Jalal Sadeghi Sharif⁴,
Seyed Ali Hosseiny Esfidavajani⁵

Received: 2024/07/05

Accepted: 2024/12/07

Research Paper

Abstract

The dynamics of the market and the stochastic behavior of index time series worldwide have made forecasting trends a primary concern for researchers and investors in the capital market. Therefore, various models are used for forecasting. Time series analysis and prediction methods based on networks, including the visibility graph model, have proven effective for time series analysis. In this research, we aimed to predict the TEDPIX index for the years 2013-2024 using three visibility graph-based methods. These methods include the most similar node model, the weighted similar node model, and our proposed method, the cross-visibility graph model. We converted the time series of the index and some auxiliary variables into a visibility graph and predicted the aforementioned time series using these three models. The results showed that the performance of the weighted similar node model and the most similar node model varied depending on different conditions. However, our proposed model, the cross-visibility graph model, and the weighted similar node model generally provided the best results in predicting the index and were more accurate compared to other models.

Key Words: Index Prediction, Complex Networks, Visibility Graph, Macro Variables, Competitor Market Variable.

JEL Classification: F17, G17, E47, C63.

1. doi: 10.22034/JSE.2024.12247.2151

2. Assistant Professor, Department of Finance and Accounting, Faculty of Management and Accounting, Shahid Beheshti University, Tehran, Iran. (Corresponding Author). (m_osoolian@sbu.ac.ir).

3. Ph.D. Student, Department of Financial Management, Faculty of Management and Accounting, Shahid Beheshti University, Tehran, Iran. (neda.mobayen@gmail.com).

4. Assistant Professor, Department of Finance and Accounting, Faculty of Management and Accounting, Shahid Beheshti University, Tehran, Iran. (j_sadeghisharif@sbu.ac.ir).

5. Associate Professor, Department of Physics, Shahid Beheshti University, Tehran, Iran. (al_hosseiny@sbu.ac.ir).



Copyright © 2025 The Authors. Published by Securities and Exchange Organization.
This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license (<https://creativecommons.org/licenses/by-nc/4.0/>). Non-commercial uses of the work are permitted, provided the original work is properly cited.



سازمان بورس و اوراق بهادار، مرکز پژوهش، توسعه و مطالعات اسلامی

فصلنامه بورس و اوراق بهادار، سال هفدهم، شماره ۶۸، زمستان ۱۴۰۳، صص ۲۰-۱

پیش‌بینی شاخص بورس اوراق بهادار به کمک گراف پدیداری^۱

محمد اصولیان^۲، ندا مبین^۳، سیدجلال صادقی شریف^۴، سیدعلی حسینی اسفیدواجانی^۵

تاریخ دریافت: ۱۴۰۳/۰۴/۱۵

تاریخ پذیرش: ۱۴۰۳/۰۹/۱۷

مقاله پژوهشی

چکیده

پویایی بازار و رفتار تصادفی سری زمانی شاخص در دنیا باعث شده پیش‌بینی روند آن از دغدغه اصلی پژوهشگران و سرمایه‌گذاران بازار سرمایه شود و بنابراین از مدل‌های مختلف برای پیش‌بینی استفاده شد. روش‌های تحلیل سری‌های زمانی مبتنی بر شبکه و پیش‌بینی از جمله مدل گراف پدیداری نشان می‌دهد که این روش‌ها برای تحلیل سری‌های زمانی مؤثر است. در این پژوهش سعی بر این داشته‌ایم که به کمک سه روش گراف پدیداری به پیش‌بینی شاخص TEDPIX در سال‌های ۱۳۹۲ تا ۱۴۰۳ پردازیم. این روش‌ها شامل مشابه‌ترین گره، مدل گره‌های مشابه وزن‌دار، و مدل ابداعی پژوهش مدل گراف پدیداری متقاطع هستند. در این راستا سری زمانی شاخص و چند متغیر کمکی را به گراف پدیداری تبدیل کرده و به کمک سه مدل به پیش‌بینی سری‌های زمانی بیان شده در بالا پرداختیم. نتایج نشان داد که عملکرد مدل گره‌های مشابه وزن‌دار و مدل مشابه‌ترین گره بسته به شرایط مختلف گاهی بهتر از دیگری بوده است. با این حال، مدل ابداعی ما یعنی مدل گراف پدیداری متقاطع و مدل گره‌های مشابه وزن‌دار، به‌طور کلی در پیش‌بینی شاخص بهترین نتایج را به دست آورده است.

واژه‌های کلیدی: پیش‌بینی شاخص، متغیرهای کلان، متغیرهای بازار رقیب، شبکه‌های پیچیده، گراف پدیداری.

طبقه‌بندی موضوعی: F17، G17، E47، C63.

doi: 10.22034/JSE.2024.12247.2151

۲. استادیار، دانشکده مدیریت، دانشگاه شهید بهشتی، تهران، ایران. (نویسنده مسئول). (m_osoolian@sbu.ac.ir).

۳. دانشجوی دکتری، گروه مدیریت مالی، دانشکده مدیریت، دانشگاه شهید بهشتی، تهران، ایران. (neda.mobayen@gmail.com).

۴. استادیار، دانشکده مدیریت، دانشگاه شهید بهشتی، تهران، ایران. (j_sadeghisarifi@sbu.ac.ir).

۵. دانشیار، دانشکده فیزیک، دانشگاه شهید بهشتی، تهران، ایران. (al_hosseiniy@sbu.ac.ir).

حق انتشار این مستند، متعلق به نویسندگان آن است. © ۱۴۰۳. ناشر این مقاله، سازمان بورس و اوراق بهادار است.

این مقاله تحت گواهی زیر منتشر شده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز است.



Creative Commons Attribution-NonCommercial 4.0 International license
(https://creativecommons.org/licenses/by-nc/4.0/)

مقدمه

پویایی بازار و رفتار تصادفی سری‌های زمانی منجمله سری زمانی شاخص بورس اوراق بهادار پیش‌بینی روند آن را چالش برانگیز کرده است (کوشکی و اصولیان، ۲۰۲۰). بنابراین پیش‌بینی روند بازار که از دغدغه‌های اصلی پژوهشگران و سرمایه‌گذاران بازار سرمایه است باعث توجه فراوانی از دیرباز به این معقوله شده است. تجزیه و تحلیل و پیش‌بینی سری‌های زمانی نقطه مهمی در پژوهش‌های سری‌های زمانی است و پیش‌بینی مقادیر آتی بر اساس داده‌های تاریخی موجود، جهت‌گیری مهم پژوهش‌های سری‌های زمانی است. روش‌های کلاسیک به کار رفته در پیش‌بینی سری‌های زمانی به صورت گسترده در بسیاری از زمینه‌ها منجمله انرژی (دب، ژانگ، یانگ، لی و شاه^۱، ۲۰۱۷)، مالی (باو، یو و راو^۲، ۲۰۱۷؛ کوشکی و همکاران، ۲۰۲۳) و پزشکی (چیمولا و ژانگ^۳، ۲۰۲۰ و مرید و شنگ^۴، ۲۰۲۳) استفاده شده‌اند. بنابراین ضرورت ارائه مدلی که از دقت بالایی برخوردار باشد همواره در میان سرمایه‌گذاران حس می‌شود. مدل‌های کلاسیک بسیاری مانند مدل پیش‌بینی هولت^۵ (هولت^۶، ۲۰۰۴)، میانگین متحرک خودهمبسته یکپارچه ((ARIMA (باکس، جنکینز، راینسل و لجانگ^۷، ۲۰۰۸) در این راستا مورد استفاده قرار گرفته است. در کنار مدل‌های کلاسیک بسیاری از مدل‌های پیش‌بینی جدید برای بهبود قابلیت پیش‌بینی ارائه شدند که از جمله این مدل‌ها می‌توان به یادگیری عمیق از جمله شبکه‌های عصبی (وانگ، وانگ، کیو و لیو^۸، ۲۰۱۸ و وانگ، دنگ، لی، ژانگ، لی و وو^۹، ۲۰۱۷؛ آسیائی طاهری و همکاران، ۲۰۲۴)، نظریه فازی (سدایی و سیلوا^{۱۰}، ۲۰۱۹)، ARIMA بهبود یافته (بویوکسahin و ارتکین^{۱۱}، ۲۰۱۹)، نظریه‌های هیبرید (حاجی رحیمی و خاشعی^{۱۲}، ۲۰۱۹ و ۲۰۲۳) اشاره کرد.

1. Deb, Zhang, Yang, Lee & Shah
2. Bao, Yue & Rao
3. Chimmula & Zhang
4. Morid & Sheng
5. Holt ES
6. Holt
7. Box, Jenkins, Reinsel & Ljung
8. Wang, Wang, Qu & Liu
9. Wang, Deng, Li, Zhang, Li & Wu
10. Sadaei, Silva
11. Büyüksahin & Ertekin
12. Hajirahimi & Khashei

طبیعت پویای بازار مالی می‌تواند به عنوان یک شبکه پیچیده نگاشته شود (سلیمانی سروستانی و همکاران، ۲۰۲۴). در واقع، از آنجایی که بازار سهام دارای داده‌های کلان است و این داده‌ها به طور مرتب در حال تغییر هستند و نوسان دارند پس لزوم استفاده از علم شبکه در دنیای بازار سهام کاملاً آشکار است زیرا با این حجم از داده‌ها، تصمیم‌گیری برای مدیران و سرمایه‌گذاران شرکت‌ها بسیار سخت است (چارسوقی و رحیم نژاد، ۱۳۹۵). با توجه به این که نظریه شبکه پیچیده به دلیل توانایی خود در استخراج اطلاعات در بسیاری از زمینه‌ها به موفقیت‌های بزرگی دست یافته است، برخی از پژوهشگران روش‌های تحلیل سری‌های زمانی مبتنی بر شبکه (زو، دونر، ماروان، دونجز، کورتز^۱، ۲۰۱۹) و پیش‌بینی (دمرتزیس، تسیوتاس و ماگافاس^۲، ۲۰۲۰) را ارائه کرده‌اند که نتایج نشان می‌دهد که روش مبتنی بر شبکه برای تحلیل سری‌های زمانی مؤثر است. توجه بسیاری از پژوهشگران به دلیل توانایی فوق‌العاده مدل گراف پدیداری برای تبدیل سری‌های زمانی به شبکه جلب شد که این روش توسط لاکاسا در سال ۲۰۰۸ پیشنهاد شد. در این مدل گره‌ها با نقاط داده سری زمانی مطابقت دارند و یک یال برای اتصال دو گره در صورتی که بتوانند یکدیگر را ببینند اختصاص داده می‌شود. الگوریتم گراف پدیداری می‌تواند انواع سری‌های زمانی را با تبدیل یک سری تناوبی به یک نمودار معمولی، یک سری تصادفی به یک نمودار تصادفی و یک دنباله فراکتال را به یک شبکه بدون مقیاس نگاشت کند (لاکاسا، لوکو، بالستروس، لوکو و نونو^۳، ۲۰۰۸، وانگ، ژو، تیان و استلی^۴، ۲۰۱۸).

در این پژوهش از سه مدل برای پیش‌بینی سری‌های زمانی شاخص کل استفاده خواهیم کرد: مدل پیش‌بینی با کمک گراف پدیداری از طریق متشابه‌ترین گره، مدل گره‌های متشابه وزن‌دار و مدل گراف پدیداری متقاطع. در مدل پیش‌بینی با کمک گراف پدیداری از طریق متشابه‌ترین گره، سری‌های زمانی شاخص کل به گراف پدیداری متناظر با آن نگاشت می‌شوند و سپس به کمک پیش‌بینی میزان شباهت گره‌ها، سعی در تخمین و پیش‌بینی داده‌های آتی در سری زمانی خواهیم کرد. ماو و ژاو^۵ در سال ۲۰۱۹ این روش را برای پیش‌بینی سری زمانی بر اساس تجزیه و تحلیل شبکه پیچیده ارائه دادند. برای اثبات اعتبار روش پیشنهادی، انواع مختلفی از مجموعه‌های سری زمانی را مورد بررسی و پیش‌بینی قرار خواهیم داد. در مدل گره‌های متشابه

-
1. Zou, Donner, Marwan, Donges & Kurths
 2. Demertzis, Tsiotas & Magafas
 3. Lacasa, Luque, Ballesteros, Luque & Nuno
 4. Wang, Xu, Tian & Stanley
 5. Mao & Xiao

وزندار (ژان و ژاو^۱، ۲۰۱۹) با وزن دادن به گره‌های متشابه سعی در پیش‌بینی داده‌های آتی سری زمانی خواهیم کرد. افزون بر این، مدل ابداعی ما، مدل گراف پدیداری متقاطع نیز برای پیش‌بینی شاخص کل معرفی می‌شود که در این مدل ابتدا از روش گراف پدیداری متقاطع (مهربان، شیرازی، زمانی و جعفری^۲، ۲۰۱۳) سری زمانی شاخص کل و سری زمانی ثانویه به گراف پدیداری متناظر با آن نگاشت شده و در ادامه با استفاده از روش گره‌های متشابه وزندار به پیش‌بینی خواهیم پرداخت. به این مدل‌ها با هدف پیش‌بینی دقیق‌تر و کاهش خطاها به کار گرفته می‌شوند. تجزیه و تحلیل خطا نشان می‌دهد که این روش و دوروش مورد مقایسه عملکرد پیش‌بینی قابل قبولی دارد.

جامعه آماری پژوهش حاضر شامل شاخص کل بورس اوراق بهادار تهران در سال‌های ۱۳۹۲ تا ۱۴۰۳ است ولی برای بررسی بیشتر در دو مدل اول متغیرهای نفت و طلا، نرخ سکه بهار آزادی، نرخ دلار به ریال و نرخ یورو به ریال در بازه زمانی متناظر با متغیر اصلی را نیز در نظر گرفته و در مدل سوم از این متغیرها برای بررسی متغیر اصلی TEDPIX استفاده خواهیم کرد. ساختار این مقاله به صورت زیر خواهد بود: در بخش دوم، ادبیات موضوع و مرور مطالعات قبلی در زمینه شبکه پیچیده و گراف پدیداری خواهیم پرداخت و سپس در بخش سوم، مبانی ریاضی و متدولوژی مورد نیاز مورد بررسی قرار داده و در نهایت، با نتیجه‌گیری به مقاله پایان خواهیم داد.

ادبیات موضوع و پیشینه پژوهش

بازار سرمایه در هر کشوری از مهم‌ترین بخش‌های اقتصاد محسوب می‌شود و تغییر و تحولات آن می‌تواند منعکس‌کننده تمام عیار ساختار اقتصادی آن کشور باشد. قیمت‌ها و در نتیجه بازدهی اوراق در این بازارها از عوامل متعددی متأثر می‌شود که در حالت کلی به عوامل درونی و بیرونی تقسیم‌بندی می‌شوند. متغیرهای کلان اقتصادی، عمده عوامل بیرونی مؤثر بر بازدهی اوراق و به ویژه سهام محسوب می‌شوند (رضازاده، ۱۳۹۵، ۱۲۱-۱۳۶). در چند دهه اخیر افزایش محبوبیت معاملات مبتنی بر شاخص و گسترده‌گی متغیرهای تأثیرگذار بر آن باعث شده است تا مفاهیم مرتبط با پیش‌بینی نوسانات شاخص قیمت سهام، هم برای محققان و پژوهشگران و هم برای سرمایه‌گذاران اهمیت

1. Zhan & Xiao

2. Mehraban, Shirazi, Zamani & Jafari

زیادی پیدا کند (وی^۱، ۲۰۱۲). در ایران نیز، با گسترش ابزارهای مالی مانند صندوق‌های شاخصی (ایجاد اولین صندوق شاخصی از سال ۱۳۸۹)، این موضوع اهمیت ویژه‌ای پیدا کرده است. این صندوق‌ها که عملکرد آن‌ها به طور مستقیم به شاخص‌های بازار سرمایه وابسته است، نقش مهمی در جذب سرمایه‌گذاران و مدیریت ریسک در بازار ایفا می‌کنند (سالاردینی، عبده تبریزی، چیت‌سازان و عباسیان، ۱۳۹۹، ۱۰۳-۱۲۷). در این راستا پژوهش‌های متعددی انجام شده است که به عنوان مثال می‌توان به پژوهش راعی، نیک‌عهد و حبیبی (۱-۲۳، ۱۳۹۵) اشاره کرد که در مطالعه‌ای با عنوان پیش‌بینی شاخص بورس اوراق بهادار تهران با ترکیب روش‌های آنالیز مؤلفه‌های اصلی، رگرسیون بردار پشتیبان و حرکت تجمعی ذرات، به منظور افزایش دقت پیش‌بینی شاخص بورس اوراق بهادار تهران، ترکیبی از روش‌های آماری و هوش مصنوعی استفاده کردند. مدل اصلی پیش‌بینی در این پژوهش از رگرسیون بردار پشتیبان بهینه شده با الگوریتم حرکت تجمعی ذرات که از قویترین الگوریتم‌های بهینه‌سازی می‌باشد، استفاده شده است. نتایج بدست آمده نشان داد که انتخاب صحیح ورودی‌ها و کاهش بعد داده‌ها می‌تواند باعث بهبود عملکرد ماشین‌های بردار پشتیبان در پیش‌بینی سری زمانی شاخص بورس اوراق بهادار تهران شود.

در پژوهش رنجبر ناوی، ارشدی و چناری (۱۱۵-۱۳۷، ۱۴۰۰) با عنوان «پیش‌بینی شاخص کل قیمت سهام با استفاده از الگوی خاکستری» به بررسی شاخص کل سهام با استفاده از الگوی خاکستری پرداختند و مدل خود را با الگوریتم شبکه عصبی و مورد مقایسه قرار دادند. نتایج نشان‌دهنده این است که خطاهای حاصل از پیاده‌سازی الگوریتم‌های بیان شده در بالا، سطح خطای الگوریتم خاکستری بهبود یافته نسبت به الگوریتم خاکستری و شبکه عصبی خطای کمتر و قدرت و دقت پیش‌بینی بیشتری را دارا است.

شبکه پیچیده بتازگی یک موضوع پژوهشی مورد توجه پژوهشگران است که بر بسیاری از زمینه‌های پژوهشی و کاربردی تاثیرگذار است (چو، هو، شن، وانگ و لی^۲، ۲۰۱۹). مشکلات چالش برانگیز در مطالعات شبکه پیچیده شامل پیش‌بینی لینک (کاشیما، ماتو، یمیشی، سوچیاما و تسودا^۳، ۲۰۰۹)، تجزیه و تحلیل آسیب‌پذیری گره‌ها (ون، سانگو جیانگ^۴، ۲۰۱۸)، تصمیم‌گیری [لای، چانگ، انگ و چیونگ^۵، ۲۰۲۰]، نظریه بازی (یی، هانگ، کوه، میزاک، چیونگ و

1. Wei

2. Chu, Hu, Shen, Li, Boccaletti, Shi & Wang

3. Kashima, Kato, Yamanishi, Sugiyama & Tsuda

4. Wen, Song & Jiang

5. Lai, Chang, Ang & Cheong

ژی^۱، ۲۰۲۰) است. اطلاعات بدست آمده از شبکه می‌تواند به ما در درک بهتر ویژگی‌های سری‌های زمانی و پیش‌بینی‌های بهتر کمک کند. بنابراین پژوهش‌های زیادی روی چگونگی مدل‌سازی سری‌های زمانی در قالب شبکه انجام شده است (از کان و اگودوکو^۲، ۲۰۱۹). الگوریتم گراف پدیداری توسط لاکاسا و همکاران (۲۰۰۸) ارائه شده است که یک سری زمانی را به یک شبکه پیچیده تبدیل می‌کند. گراف پدیداری همچنین می‌تواند در بسیاری از زمینه‌ها و برنامه‌ها مانند پردازش تصویر (لاکواچیو لاکاسا^۳، ۲۰۱۹)، تصمیم‌گیری (ماو، دنگ و پلوسی^۴، ۲۰۲۰) و غیره استفاده شود. برخی از این روش‌های پیش‌بینی سری‌های زمانی مبتنی بر الگوریتم گراف پدیداری ارائه شده‌اند. برای مثال، برای مثال، ژانگ، آشوری و دنگ^۵ (۲۰۲۰) پیشنهاد کردند که از الگوریتم گام تصادفی (لیو و لو^۶، ۲۰۱۰) به عنوان مرجعی برای پیش‌بینی سری‌های زمانی استفاده شود. در گذشته، نتیجه پیش‌بینی بر اساس الگوریتم گراف پدیداری تنها به یک گره زمانی در پایان بستگی داشت. در نتیجه هنگامی که سری زمانی بزرگتر می‌شود، از آنجایی که نتیجه پیش‌بینی در پایان تنها به یک گره زمانی بستگی دارد، خطاهای بیشتری ایجاد می‌شود (ما و ژاو^۷، ۲۰۱۹).

اگرچه برخی از روش‌های پیشنهادی مبتنی بر شبکه‌های پیچیده عملکرد خوبی در پیش‌بینی برخی از سری‌ها دارند اما چگونگی استخراج اطلاعات بیشتر از سری‌های زمانی و پیش‌بینی دقیق‌تر هنوز یک پرسش باز است. برای پرداختن به این موضوع، هو و ژاو^۸ (۲۰۲۲) یک روش جدیدی را بر اساس گراف پدیداری هدایت‌شده و فرآیند گام تصادفی پیشنهاد کردند. ابتدا سری زمانی مورد نظر برای استخراج اطلاعات بیشتر بازسازی می‌شود. سپس سری بازسازی شده به یک گراف پدیداری جهت دار تبدیل می‌شود و در نهایت برای پیش‌بینی سری زمانی مورد نظر استفاده می‌شود. نتایج آزمایش آنها نشان می‌دهد که روش پیشنهادی توانایی ارائه پیش‌بینی‌های دقیق‌تری نسبت به روش‌های مشابه دارد. شن، لیو، ژانگ و ژانگ^۸ (۲۰۱۹) یک گراف پدیداری وزن‌دار ساختند که در آن وزن یال‌ها به عنوان ترکیبی از تفاوت قیمت و فاصله

1. Ye, Hang, Koh, Miszczak, Cheong & Xie

2. Ozcan, & Oguducu

3. Iacovacci, & Lacasa

4. Mao, Deng & Pelusi

5. Zhang, Ashuri & Deng

6. Liu & Lü

7. Hu & Xiao

8. Chen, Liu, Zhang & Zhang

زمانی گره‌های مربوطه تعریف می‌شود. سپس با آزمایش آن بر روی ۱۲ شاخص، نشان دادند این مدل نتایج بهتری نسبت به مدل‌های قبلی ارائه می‌کند.

در این پژوهش ما به پیش‌بینی سری‌های زمانی در چارچوب شبکه‌های پیچیده خواهیم پرداخت. در این راستا از برخی مدل‌ها برای ساخت گراف پدیداری استفاده کرده و به مقایسه نتایج به دست آمده خواهیم پرداخت.

روش‌شناسی پژوهش


در این بخش به روشی خواهیم پرداخت که در آن سری‌های زمانی به گراف پدیداری متناظر با آن نگاشته می‌شوند و سپس به کمک پیش‌بینی میزان شباهت گره‌ها، سعی در تخمین و پیش‌بینی داده‌های آتی در سری زمانی خواهد کرد. ماو و ژاو (۲۰۱۹) این روش را برای پیش‌بینی سری زمانی بر اساس تجزیه و تحلیل شبکه پیچیده ارائه دادند. برای اثبات اعتبار روش پیشنهادی، انواع مختلفی از مجموعه‌های سری زمانی را مورد بررسی و پیش‌بینی قرار خواهیم داد و در بخش آزمایشی نتایج با دو مدل پیش‌بینی دیگر مقایسه و تجزیه و تحلیل خطا نشان می‌دهد که این روش عملکرد پیش‌بینی خوبی دارد.

پیش‌بینی به کمک گراف پدیداری از طریق مدل متشابه‌ترین گره

گراف پدیداری توصیف مناسبی از یک سری زمانی در چارچوب شبکه‌های پیچیده است که این گراف به کمک الگوریتم گراف پدیداری از روی یک سری زمانی پدید می‌آید. سری زمانی (t, y) را در نظر بگیرید. طبق پژوهش لاکاسا^۱ و همکاران (۲۰۰۸) هر نقطه از این سری زمانی توسط یک عملگر یک به یک به یک گره در گراف پدیداری نگاشت می‌شود و هر دو نقطه از این سری زمانی مانند نقاط (t_i, y_i) و (t_j, y_j) را دو نقطه پدیدار گویند اگر مابین گره‌های متناظر با این دو نقطه یال وجود داشته باشد. شرط وجود یال در گراف پدیداری به این صورت است که برای تمامی نقاط مابین دو نقطه (t_i, y_i) و (t_j, y_j) که آن را (t_k, y_k) بنامیم شرط زیر برقرار باشد:

$$y_k < \frac{t_j - t_k}{t_j - t_i} (y_i - y_j) + y_j \quad (1)$$

شکل ۱ به خوبی بیان‌گر نحوه اتصال دو گره متناظر با دو نقطه در یک سری زمانی است. همان طوریکه در شکل مشخص است، میله عمودی نشان‌دهنده گره بوده و یال که دو میله عمودی را به هم متصل می‌کند نشان‌دهنده پیوند در شبکه است. دو گره در صورتی به هم متصل می‌شوند که نیازهای معیارهای پدیداری را تامین کنند.



شکل ۱. شرح نمودار پدیداری به صورت شماتیک یک سری زمانی شامل ۱۰ مقدار داده به یک گراف پدیداری تبدیل می‌شود. میله های عمودی نشان دهنده گره ها و خطوط متصل کننده دو میله نشان دهنده یال های شبکه هستند.

شباهت گره‌ها

اینک با داشتن گراف پدیداری متناظر با یک سری زمانی، نیاز داریم که میزان شباهت هر دو گره در گراف پدیداری که با یک یال به همدیگر اتصال دارند را مشخص کنیم. پس از این مرحله شبکه ما یک شبکه وزن‌دار خواهد بود و وزن هر کدام از یال‌ها مقدار شباهت دو گره متناظر را نشان خواهد داد. معادله زیر تعریف میزان شباهت گره‌های x و y را ارائه می‌دهد.

$$S_{xy}^{LRW}(t) = \frac{k_x}{2|E|} \pi_{xy}(t) + \frac{k_y}{2|E|} \pi_{xy}(t) \quad (2)$$

در این معادله $S_{xy}^{LRW}(t)$ بیانگر میزان شباهت دو گره x و y در زمان t است که در چارچوب روش LRW محاسبه می‌شود. k_x بیانگر درجه گره x است و $\pi_{xy}(t)$ احتمال اینکه در زمان t از گره x به گره y حرکت کنیم را نشان می‌دهد. در نهایت E بیانگر تعداد کل یال‌های موجود در شبکه است. در یک شبکه، این احتمال که یک حرکت کننده تصادفی از گره x خارج شود به صورت $\vec{\pi}_x$ نشان داده می‌شود. در زمان t یک مقدار کافی برای تضمین این مسئله است که فرد حرکت کننده قادر به حرکت کامل در شبکه است)، $(t) \vec{\pi}_x$ به صورت زیر محاسبه می‌شود:

$$\vec{\pi}_x(t) = p^T \vec{\pi}_x(t-1) \quad (3)$$

باید به این نکته اشاره داشت که p^T در واقع ترانواده ماتریس احتمال انتقال (P) است. احتمال حرکت از گره x به گره y در یک مرحله به صورت زیر نشان داده می‌شود.

$$\vec{\pi}_{xy} \cdot P_{xy} = \frac{a_{xy}}{k_x} \quad (3)$$

که در آن اگر نقطه x به نقطه y متصل شود، $a_{xy} = 1$ خواهد بود، در غیر این صورت $a_{xy} = 0$ خواهد بود. علاوه بر این، k_x به معنای درجه گره x است. $\vec{\pi}_x(t)$ یک بردار $N \times 1$ است که حالت اولیه گره x را نشان می‌دهد. در این وضعیت، عنصر x برابر با ۱ بوده و بقیه برابر با صفر هستند.

با گذشت زمان در هر مرحله، مقادیر $S_{xy}^{LRW}(t)$ را به دست آورده و در نهایت، براساس (لیو و لو، ۲۰۱۰)، بالاترین شباهت بین گره x و گره y را می‌توان با جمع نتایج S_{xy}^{LRW} در هر زمان به صورت زیر محاسبه کرد.

$$S_{xy}^{SRW}(t) = \sum_{l=1}^t S_{xy}^{LRW}(l) \quad (4)$$

که در آن $S_{xy}^{SRW}(t)$ به مفهوم میزان شباهت گره‌ها در شبکه برهم نهی شده در طول زمان (t) است.

فاصله گره‌ها

براساس پژوهش ژانگ و همکاران (۲۰۱۷)، فاصله گره در یک گراف پدیداری به کمک معادله زیر تعریف می‌شود.

$$d_{i \rightarrow j} = |t_i - t_j| \quad (5)$$

که در آن t_i و t_j مقادیر زمانی معادل در نقطه (t_i, y_i) و گره (t_j, y_j) هستند. بر مبنای معادله بالا، فاصله بین دو نقطه با بالاترین شباهت (t_M, y_M) و (t_N, y_N) توسط معادله زیر تعیین می‌شود.

$$d_{M \rightarrow N} = |t_N - t_M| \quad (۶)$$

اگر گره پیش‌بینی شده به صورت (t_{N+1}, y_{N+1}) نشان داده شود، فاصله بین آخرین گره (t_N, y_N) و نقطه بعدی آن t_{N+1}, y_{N+1} به وسیله معادله زیر محاسبه می‌شود.

$$d_{N \rightarrow N+1} = |t_{N+1} - t_N| \quad (۷)$$

به همین منوال، فاصله بین گره (t_M, y_M) و گره بعدی (t_{N+1}, y_{N+1}) توسط معادله زیر تعیین می‌شود.

$$d_{M \rightarrow N+1} = |t_{N+1} - t_M| \quad (۸)$$

الگوریتم پیشنهادی گام به گام جهت پیش‌بینی

بر مبنای مسئله شباهت گره و فاصله گره، روش پیش‌بینی تعیین می‌شود.

نخست با در نظر گرفتن دو فاکتور مهم زیر است که گره (t_M, y_M) و گره (t_N, y_N) برای تعیین گره بعدی (t_{N+1}, y_{N+1}) ترکیب می‌شوند.

۱. مشابه‌ترین گره (t_M, y_M)

شباهت‌ها بین آخرین گره (N) و $(N-1)$ ، گره‌های پیشین توسط معادله زیر نشان داده می‌شود.

$$S^{SRW} = [S_{1N}, S_{2N}, \dots, S_{MN}, \dots, S_{(N-1)N}] \quad (۹)$$

حداکثر مقدار S^{SRW} به صورت S_{MN} نشان می‌دهیم. بر همین اساس، گره (t_M, y_M) معادل با S_{MN} به عنوان شبیه‌ترین نقطه به گره (t_N, y_N) است.


در پیش‌بینی سری زمانی، مقادیر آتی را بر مبنای مقادیر مشاهده شده پیش‌بینی می‌کنیم و گره (t_M, y_M) نماینده داده‌های پیشین است. این گونه در نظر گرفته می‌شود که این گره حاوی تمامی اطلاعات پیشین است در نتیجه برای پیش‌بینی مقدار آتی قابل استفاده است.

۲. آخرین گره مشاهده شده (t_N, y_N)

گره (t_N, y_N) نزدیک ترین نقطه به گره بعدی (t_{N+1}, y_{N+1}) است. افزون بر این، این مورد پیوندی مستقیم با گره (t_{N+1}, y_{N+1}) خواهد داشت. بنابراین، آخرین مقدار مشاهده شده y_N دارای تاثیری مستقیم بر مقدار پیش‌بینی شده y_{N+1} دارد.

$$y_{N+1} = y_N + \frac{y_N - y_M}{t_N - t_M} (t_{N+1} - t_N) \quad (10)$$

از آنجا که گره (t_M, y_M) و گره (t_N, y_N) دارای بالاترین شباهت هستند، به منظور محاسبه مقدار آتی y_{N+1} با هم پیوندی خطی دارند.



شکل ۲. دو نقطه مشابه، گره (t_8, y_8) و گره (t_4, y_4) برای تعیین مقدار y_9 .

۱. تاثیر فاصله در پیش‌بینی
به طور معمول، هرچه قدر گره (t_M, y_M) از گره (t_N, y_N) دورتر باشد، گره (t_M, y_M) اهمیت بیشتری می‌یابد چون اطلاعات تاریخی بیشتری را با خود حمل می‌کند. برعکس، اگر گره (t_M, y_M) نزدیکی زیادی به گره (t_N, y_N) داشته باشد، اهمیت گره (t_M, y_M) کاهش می‌یابد چون حاوی

اطلاعات کمتری در مورد گذشته بوده و تاثیر کمایش مشابهی با گره (t_N, y_N) برای پیش‌بینی‌های آتی خواهد داشت. بر مبنای این مسئله، ضریب‌های وزنی را به صورت زیر تعریف می‌کنیم.

$$W_{N+1} = \frac{d_{M \rightarrow N}}{d_{M \rightarrow N+1}} \quad (11)$$

$$W_N = \frac{d_{N \rightarrow N+1}}{d_{M \rightarrow N+1}} \quad (12)$$

که در آن W_{N+1} بیانگر ضریب وزن y_{N+1} بوده و W_N بیانگر ضریب وزن آخرین مقدار مشاهده y_N است. همانطوری که از معادله‌های (۱۲) و (۱۳) مشخص است اگر $d_{M \rightarrow N}$ افزایش یابد، ضریب وزن y_{N+1} یعنی W_{N+1} ، بزرگتر می‌شود، حال آنکه W_N کوچکتر می‌شود. برعکس، زمانی که $d_{M \rightarrow N}$ کاهش یابد، W_{N+1} کوچکتر شده و W_N بزرگتر می‌شود. بنابراین، نتایج پیش‌بینی نهایی با کمک معادله زیر محاسبه می‌شوند.

$$\hat{y}_{N+1} = W_{N+1} \times y_{N+1} + W_N \times y_N \quad (13)$$

پیش‌بینی به کمک گراف پدیداری از طریق مدل گره‌های متشابه وزن‌دار

ژاو و ژان (۲۰۲۱) مطرح می‌کند که در مطالعات قبلی، نتیجه پیش‌بینی بر اساس گراف پدیداری تنها به یک گره زمانی در پایان بستگی دارد. بنابراین هنگامی که سری زمانی بزرگتر می‌شود، خطاهای بیشتری ایجاد می‌کند. آنها در مقاله خود به یک روش جدید پیش‌بینی سری زمانی بر اساس گراف پدیداری پیشنهاد می‌کند که با وزن‌دهی به گره‌ها، خطای پیش‌بینی سری‌های زمانی را کاهش می‌دهد. در این روش بعد از تبدیل سری زمانی به گراف پدیداری و یافتن تشابه گره‌ها، ابتدا بردار وزنی گره‌های مشابه را محاسبه کرده سپس بردار پیش‌بینی اولیه محاسبه و بر اساس آن مقدار را پیش‌بینی می‌کنند. با این حال، روش پیشنهادی با افزایش مجموعه داده‌ها و افزایش منابع اطلاعاتی، دقت را بهبود می‌بخشد.

الگوریتم پیشنهادی گام به گام جهت پیش‌بینی

۱. ابتدا مانند مدل قبل سری زمانی خود را به صورت گراف پدیداری در آورده و سپس میزان شباهت هر دو گره در گراف پدیداری که با یک یال به همدیگر اتصال دارند را به از طریق LRW را مشخص کرده و سپس بالاترین شباهت بین گره x و گره y را می‌توان با جمع نتایج S_{xy}^{LRW} در هر زمان محاسبه می‌کنیم.

$$S_{xy}^{LRW}(t) = \frac{k_x}{2|E|} \pi_{xy}(t) + \frac{k_y}{2|E|} \pi_{xy}(t) \quad (14)$$

$$S_{xy}^{SRW}(t) = \sum_{l=1}^t S_{xy}^{LRW}(l) \quad (15)$$

۲. محاسبه شباهت وزنی:

شباهت وزنی (WS)، بردار واحد را بر اساس شباهت SRW نشان می‌دهد که به صورت زیر محاسبه می‌شود.

$$\vec{S}_N^{WS} = (S_{(1,N)}^W(t), S_{(2,N)}^W(t), S_{(3,N)}^W(t), \dots, S_{(N-1,N)}^W(t)) \quad (16)$$

WS مقدار بردار SRW را تبدیل به واحد کرده که به صورت زیر محاسبه می‌شود:

$$S_{(x,N)}^{WS}(t) = \frac{S_{(x,N)}^{SRW}(t_n)}{\sum_{i=1}^{N-1} S_{(x,i)}^{SRW}(t_i)} \quad (17)$$

$$\sum_{i=1}^{N-1} S_{(x,i)}^{WS}(t) = 1 \quad (18)$$

۳. محاسبه بردارهای پیش‌بینی اولیه

ابتدا i امین گره‌های $(N-1)$ را در نظر بگیرید. سپس برای پیش‌بینی یک نمونه واحد، مقدار مؤلفه پیش‌بینی تولید شده توسط گره i به صورت زیر تعریف می‌شود.

$$y_i^p = y_N + \frac{y_N - y_i}{t_N - t_i} (t_{N+1} - t_N) \quad (19)$$

با تجمع مقادیر پیش‌بینی شده در بردار پیش‌بینی اولیه، بردار مقدار پیش‌بینی شده YP به شرح زیر است.

$$\vec{Y}_p = (y_1^p, y_2^p, \dots, y_{N-1}^p) \quad (20)$$

۴. پیش‌بینی بر اساس وزن‌ها

با در نظر گرفتن طول هر جزء $\vec{S}_x^{WS}(t_n)$ به عنوان ضریب وزنی، مجموع وزنی اندازه مؤلفه‌های بردار پیش‌بینی $\vec{Y}_p$ نتیجه پیش‌بینی این روش است که به صورت ضریب وزنی بیان می‌شود. حاصل ضرب نقطه‌ای $\vec{S}_x^{WS}(t_n)$ و بردار پیش‌بینی $\vec{Y}_p$ که به صورت زیر تعریف می‌شود:

$$\widehat{\vec{y}_{N+1}} = \sum_{i=1}^{n-1} (S_{i,N}^{WS}(t) \times y_1^p) = \vec{S}_N^{WS}(t) \cdot \vec{Y}_p \quad (21)$$

پیش‌بینی از طریق شبکه پدیداری متقاطع

گراف پدیداری متقاطع نمایش این پرسش است که چه مقدار اطلاعات محلی از یک ساختار جهانی به دست می‌آید. بر اساس این رویکرد، ویژگی‌های جهانی جدید برای سری‌های زمانی معرفی می‌شوند. برپایه این روش، معیار دید برای دو سری زمانی نشان داده می‌شود یعنی یک سری زمانی به اجزای خود از منظر سری زمانی دیگر نگاه می‌کند. این الگوریتم چارچوبی را برای درک اینکه چگونه سری‌های زمانی پیچیده یکدیگر را هدایت می‌کنند، فراهم می‌کند و برای جریان اطلاعات بین آنها را تعیین می‌کند. این روش در پژوهش «مهربان و همکاران (۲۰۱۳)» برای تشخیص کاپلینگ بین دو سری زمانی ارائه و افزون بر این، کاپلینگ در مقیاس‌های مختلف نشان داده شده است. بررسی قابلیت دید متقاطع بین سری‌های زمانی شناخته‌شده همبسته و ناهمبسته می‌تواند معیاری برای توصیف قابلیت دید متقاطع باشد.

طبق الگوریتم پدیداری، هر جزء در سری زمانی $\{y_i\}$ با $i = 1, \dots, N$ به یک گره از یک گراف نگاشت می‌شود. گره i و گره j ($i < j$) به هم متصل می‌شوند اگر به طور مستقیم برای یکدیگر قابل مشاهده باشند یعنی گره i در سری زمانی را در صورتی می‌توان به گره j متصل کرد که بدون عبور از هر گره k در سری زمانی متصل شوند.

$$i < \forall k < j; y_k < y_i + \frac{y_j - y_i}{j - i} (k - i) \quad (22)$$

اگر گره i برای گره j قابل مشاهده باشد، گره j نیز برای گره i قابل مشاهده خواهد بود بنابراین شبکه بدون جهت خواهد بود. عناصر سری زمانی که بالاتر از سایرین قرار دارند درجات بالاتری دارند.

الگوریتم پدیداری متقاطع، دو سری زمانی $\{x_i\}$ و $\{y_i\}$ را به دو شبکه مختلف، به اصطلاح شبکه‌های پدیداری متقاطع، تبدیل می‌کند. الگوریتم از دو مرحله اصلی تشکیل شده است:

الف) برای اینکه سری‌های زمانی قابل مقایسه باشند، آنها نرمال می‌شوند تا متغیرها بدون بعد شوند. اگر توالی‌ها ثابت باشند، به میانگین و انحراف معیارشان نرمال می‌شوند. بنابراین، دنباله‌های جدید به

$$\text{صورت } \{\hat{x}_i\} = \left\{ \frac{x_i - \bar{x}}{\sigma_x} \right\} \text{ و } \{\hat{y}_i\} = \left\{ \frac{y_i - \bar{y}}{\sigma_y} \right\} \text{ تولید می‌شوند که در آن } \bar{x} \text{ و } \bar{y} \text{ مقادیر میانگین}$$

هستند، به ترتیب σ_x و σ_y انحرافات استاندارد مربوط به سری $\{x_i\}$ و $\{y_i\}$ هستند. اگر سری‌ها ناماننا باشند، به مقدار حداکثر مربوطه خود نرمال می‌شوند.

ب) هر جزء در سری زمانی $\{\hat{x}_i\}$ به یک گره از یک گراف تبدیل می‌شود. گره i و گره j متصل است، اگر:

$$i < \forall k < j; \hat{y}_k \leq \hat{y}_i + \frac{\hat{x}_j - \hat{x}_i}{j - i} (k - i) \quad (23)$$

$$i < \forall k < j; \hat{y}_k \geq \hat{y}_i + \frac{\hat{x}_j - \hat{x}_i}{j - i} (k - i) \quad (24)$$

این قانون را می‌تواند اینگونه تفسیر کرد که گره i به اجزای سری زمانی $\{\hat{x}_i\}$ ، از طریق موانع سری زمانی جابجا شده $\{\hat{y}_k - \hat{y}_i + \hat{x}_i\} = \{\hat{y}_k\}$ نگاه می‌کند. ساختار این شبکه نشان می‌دهد که چگونه سری زمانی $\{\hat{x}_i\}$ سری زمانی $\{\hat{y}_i\}$ را هدایت می‌کند. معادله (۲۴) به قابلیت رویت از نمای بالا و معادله (۲۵) دید از نمای زیر را نشان می‌دهد.


اینک با در دست داشتن گراف پدیداری متقاطع متناسب با سری زمانی مورد نظر بر طبق مدل گره‌های متشابه وزن‌دار می‌توانیم به تحلیل پیش‌بینی روند سری زمانی بپردازیم. بعد از مشخص شدن روش پژوهش با استفاده از ابزارهای مناسب، داده‌های مورد نیاز را برای پاسخ به پرسش‌ها را جمع‌آوری کرده و سپس نوبت آن فرا می‌رسد که با بهره‌گیری از تکنیک‌های مناسب با روش پژوهش، داده‌های جمع‌آوری شده را تجزیه و تحلیل کرده تا بتوان پاسخی برای پرسشی که پژوهش برای به دست آوردن آن بود را یافت.

یافته‌های پژوهش

بررسی و پیش‌بینی روند به کمک گراف پدیداری طریق مدل متشابه‌ترین گره
در مسیر پیش‌بینی روند سری‌های زمانی به کمک روش ارائه شده در بخش قبلی، ابتدا نیاز است که گراف پدیداری مربوط به یک سری زمانی محاسبه و به کمک آن به پیش‌بینی روند اقدام کرد.

گراف پدیداری

اینک با داشتن سری زمانی می‌توان گراف پدیداری مربوطه را تشکیل داد. برای این کار از کتابخانه Visibility_Graph پایتون کمک گرفته‌ایم و گراف رسم شده آن را در شکل ۳ آورده‌ایم.



شکل ۳. گراف پدیداری برای سری زمانی نفت در بازه زمانی (۲۵ اسفند ۱۳۹۷ تا ۲۵ اسفند ۱۳۹۹) که به صورت شماتیک در آن پدیدار بودن گره‌ها نسبت به یکدیگر به وضوح قابل مشاهده است.

با توجه به تعدد بالای گره‌ها که به اندازه تعداد داده‌های موجود در سری زمانی مورد نظر است، ویژگی‌های گراف پدیداری به صورت بصری قابل رویت نیست. به منظور وضوح بیشتر، این گراف را تنها برای تعداد محدودی از گره‌های رسم کرده‌ایم (بازه ۲۵ اسفند ۱۳۹۷ تا ۲۵ اسفند ۱۳۹۹) که در شکل ۳ قابل مشاهده است. برای ادامه مسیر پیش‌بینی تنها به فهرست یال‌های موجود در این گراف نیاز داریم که این فهرست نیز توسط کتابخانه Networkx پایتون قابل بازخوانی است.

گراف پدیداری از طریق مدل متشابه‌ترین گره شبیه‌ترین گره

حال با داشتن فهرست یال‌های گراف پدیداری متناسب با سری زمانی متغیرها، می‌توان معیار معرفی شده در متدولوژی برای شباهت میان گره‌ها را پیاده سازی کرد و بین هر دو گره، این مقدار را اندازه‌گیری و ثبت کرد. سپس بیشترین میزان شباهت با آن گره به همراه گره مربوطه گزارش می‌شود.

پیش‌بینی به کمک گراف پدیداری از طریق مدل گره‌های متشابه وزن‌دار


تشابه وزنی گره‌ها

در قسمت قبلی، نتیجه روش پیش‌بینی تنها به یک گره زمانی در پایان بستگی دارد. هنگامی که سری زمانی بزرگتر می‌شود، از آنجایی که نتیجه پیش‌بینی در پایان تنها به یک گره زمانی

بستگی دارد، خطاهای بیشتری ایجاد می‌شود. در این قسمت یک روش پیش‌بینی سری زمانی جدید بر اساس نمودار پدیداری ارائه شده در متدولوژی را بررسی کرده که با وزن‌دهی به گره‌های زمانی در سری‌های زمانی، خطای پیش‌بینی سری‌های زمانی را کاهش می‌دهد.

در واقع در مدل قبل از شباهت بین گره‌های زمانی برای انتخاب مشابه‌ترین برازش خطی گره زمانی استفاده می‌کرد. هنگامی که مشابه‌ترین گره زمانی انتخاب می‌شد، نتیجه پیش‌بینی تعیین می‌شد و نتیجه پیش‌بینی به مشابه‌ترین گره بستگی داشت. اما باید این را در نظر گرفت که مشابه‌ترین گره‌ها به علت ساختارهای سری زمانی مختلف محدود می‌شوند. مشابه‌ترین گره‌های زمانی شبیه‌ترین گره‌ها از نظر شبکه هستند، نه دقیق‌ترین آنها. روش پیشنهادی این مشکل را با وزن دادن به شباهت گره‌ها حل می‌کند. گره‌هایی با شباهت زیاد بیشتر به نتیجه پیش‌بینی کمک می‌کنند و قوی‌تر هستند.

با توجه به معادله (۱۵) تا (۲۲) نمودار سری زمانی پیش‌بینی شده برای شاخص کل در بازه فروردین ۱۴۰۱ تا آخر اسفند ۱۴۰۲ به صورت شکل ۴ است:



شکل ۴. نمودار سری زمانی پیش‌بینی شده برای شاخص کل در بازه فروردین ۱۴۰۱ تا آخر اسفند ۱۴۰۲ به کمک گراف پدیداری از طریق مدل گره‌های مشابه وزن‌دار

بررسی دقت دو مدل پیش‌بینی به کمک گراف پدیداری از طریق مدل مشابه‌ترین گره و پیش‌بینی به کمک گراف پدیداری از طریق مدل گره‌های مشابه وزن‌دار برای بررسی دقت مدل از ۴ خطای MAD ، $MAPE$ ، $RMSE$ ، $NRMSE$ استفاده کردیم که نتایج به صورت جدول ۱ و جدول ۲ است. در جدول ۱ به بررسی خطاهای پیش‌بینی شاخص در بازه‌های زمانی متفاوت با استفاده از دو مدل پیش‌بینی از طریق گراف پدیداری از طریق مدل

متشابه‌ترین گره و مدل گره‌های متشابه وزن‌دار مورد بررسی قرار گرفت. نتایج نشان داد که در هر دو مدل با زیاد شدن داده‌های مورد بررسی خطای MAPE زیاد و NRMSE کاهش می‌یابد. در بازه ۳ ماهه مدل متشابه‌ترین گره خطای RMSE برابر با ۱۲۷۸۹,۷۵ و مدل گره‌های متشابه وزن‌دار خطای RMSE برابر با ۱۲۲۶۳,۴۲ دارد. مدل گره‌های وزن‌دار عملکرد بهتری با NRMSE و MAPE کمی کمتر دارد. در بازه ۶ ماهه دو مدل دارای خطاهای مشابهی هستند، اما مدل گره‌های وزن‌دار مجدداً اندکی بهتر عمل کرده است. خطای RMSE مدل متشابه‌ترین گره ۱۳۶۷۴,۱۵ و برای مدل گره‌های متشابه وزن‌دار ۱۳۱۶۴,۲۲ است. در بازه یک ساله از داده‌ها، اختلاف بین دو مدل بیشتر است و مدل گره‌های وزن‌دار با RMSE برابر با ۲۲۹۹۸,۵۶ عملکرد بهتری نسبت به مدل متشابه‌ترین گره دارد (RMSE برابر با ۲۳۴۰۶,۱۱). در بازه دو ساله نیز مدل گره‌های متشابه وزن‌دار خطای کمتری دارد. RMSE مدل متشابه‌ترین گره ۲۱۹۷۹,۰۳ و مدل گره‌های وزن‌دار ۲۱۱۷۹,۴ است. در کل دوره، مدل گره‌های وزن‌دار با RMSE برابر با ۱۳۷۶۴,۱۶ نسبت به مدل متشابه‌ترین گره با RMSE برابر با ۱۴۳۷۲,۰۵ بهتر عمل می‌کند. به طور کلی، مدل «گره‌های متشابه وزن‌دار» در تمامی بازه‌های زمانی، عملکرد بهتری از مدل «متشابه‌ترین گره» داشته است و دقت پیش‌بینی بیشتری دارد.

جدول ۱. خطاهای پیش‌بینی سری زمانی شاخص به کمک گراف از طریق مدل متشابه‌ترین گره و مدل گره‌های متشابه وزن‌دار در بازه‌های زمانی متفاوت

خطا بازه زمانی	مدل متشابه‌ترین گره				طریق مدل گره‌های متشابه وزن‌دار			
	MAPE (%)	MAP	NRMSE (%)	RMSE	MAPE (%)	MAP	NRMSE (%)	RMSE
۳ ماهه	۰,۲۸	۵۸۴۶,۴۵	۷,۸۸	۱۲۷۸۹,۷۵	۰,۲۷	۵۸۳۱	۷,۵۵	۱۲۲۶۳,۴۲
۶ ماهه	۰,۴	۸۲۷۰,۵	۵,۲۵	۱۳۶۷۴,۱۵	۰,۴	۸۳۶۵,۵۲	۵,۱۱	۱۳۱۶۴,۲۲
یک ساله	۰,۷۱	۱۵۱۳۷,۹۶	۲,۴۹	۲۳۴۰۶,۱۱	۰,۷	۱۵۰۸۵,۹۴	۲,۵۲	۲۳۶۹۸,۵۶
دو ساله	۰,۷۹	۱۴۳۷۴,۰۱	۱,۶۶	۲۱۹۷۹,۰۳	۰,۷۵	۱۴۰۴۲,۰۳	۱,۶	۲۱۱۷۹,۴
تمام دوره	۰,۸	۶۷۲۳,۰۵	۰,۵۸	۱۴۳۷۲,۰۵	۰,۷۶	۶۴۸۲,۸۸	۰,۵۵	۱۳۷۶۴,۱۶

با توجه به این که MAPE کمتر از ۵٪ به عنوان نشانه‌ای از قابل قبول بودن پیش‌بینی در نظر گرفته می‌شود و MAPE بیشتر از ۱۰٪ اما کمتر از ۲۵٪ نشان دهنده دقت کم، اما قابل قبول است (سوانسون^۱، ۲۰۱۵) می‌توان دریافت برای تمام سری‌های زمانی محاسبه شده در هر دو

جدول ۱، جدول ۲ و MAPE تقریباً مساوی و زیر ۱ درصد بوده است که نشان از قابل قبول بودن این مدل است.

جدول ۲ شامل مقایسه عملکرد دو مدل پیش‌بینی (مدل متشابه‌ترین گره و مدل گره‌های متشابه وزن‌دار) در پیش‌بینی سری‌های زمانی مختلف از سال ۱۳۹۲ تا ۱۴۰۲ است. این سری‌های زمانی شامل شاخص TEDPIX (شاخص کل بورس تهران)، قیمت نفت (Oil)، طلا (Gold)، سکه (Coin)، نرخ دلار به ریال (USD/IRR) و یورو به ریال (Euro/IRR) هستند.

جدول ۲. خطاهای پیش‌بینی به کمک گراف از طریق مدل متشابه‌ترین گره و مدل گره‌های متشابه وزن‌دار در بازه زمانی ۱۳۹۲ تا ۱۴۰۲

خطا سری زمانی	مدل متشابه‌ترین گره				مدل گره‌های متشابه وزن‌دار			
	MAPE (%)	MAP	NRMSE (%)	RMSE	MAPE (%)	MAP	NRMSE (%)	RMSE
TEDPIX	۰.۵۸	۶۷۲۳.۰۵	۰.۵۵	۱۳۷۶۴.۱۶	۰.۸	۶۴۸۲.۸۸	۰.۷۶	۱۴۳۷۲.۴۳
Oil	۱.۲۸	۰.۹۶	۱.۵۴	۱.۶۱	۱.۰۲	۱.۶۶	۱.۳۸	۱.۴۸
Gold	۱.۳۸	۱۱.۰۵	۰.۷۴	۱۶.۰۶	۱۱.۱۷	۰.۷	۱.۴۲	۱۵.۶۱
Coin	۰.۸۲	۱۲۱۳۲۵.۰۹	۱.۲۷	۳۵۹۱۴.۰۸	۱۵۶۹۴۶۶	۱.۴۱	۰.۹۵	۳۱۳۱۰۹۲.۷۷
USD/IRR	۰.۸۵	۲۰۶۵.۲۵	۱.۰۶	۵۷۶۱.۶۱	۲۷۰۹.۰۱	۱.۲۶	۱	۴۹۵۸.۱
Euro/IRR	۰.۸۵	۲۳۶۵.۱	۱.۱	۳۵۹۱۴.۰۸	۱۵۶۹۴۶۶	۱.۴۱	۰.۹۵	۵۳۷۵.۹۸

با توجه به جدول ۲ در سری زمانی TEDPIX، مدل متشابه‌ترین گره دارای RMSE برابر با ۱۴۳۷۲،۴۳ و مدل گره‌های متشابه وزن‌دار دارای RMSE برابر با ۱۳۷۶۴،۱۶ است که نشان‌دهنده دقت بیشتر مدل گره‌های متشابه وزن‌دار است. همچنین MAPE و NRMSE مدل گره‌های متشابه وزن‌دار کمی کمتر است. قیمت نفت در مدل متشابه‌ترین گره دارای RMSE برابر با ۱،۴۸ و گره‌های متشابه وزن‌دار دارای RMSE برابر با ۱،۶۱ است. در این سری زمانی، مدل متشابه‌ترین گره عملکرد بهتری داشته و خطای کمتری دارد. در سری زمانی قیمت طلا مدل متشابه‌ترین گره دارای RMSE برابر با ۱۵،۶۱ و مدل گره‌های متشابه وزن‌دار RMSE برابر با ۱۶،۰۶ است. در اینجا نیز مدل متشابه‌ترین گره عملکرد بهتری دارد. در سری زمانی قیمت سکه در این سری زمانی، مدل گره‌های متشابه وزن‌دار دارای RMSE کمتر (۳۵۱۹۱،۶۱) در مقابل (۳۴۱۹۲،۷) بوده و عملکرد بهتری نسبت به مدل متشابه‌ترین گره دارد. سری زمانی نرخ دلار به ریال در مدل گره‌های متشابه وزن‌دار عملکرد بهتری در پیش‌بینی نرخ دلار به ریال دارد،

چرا که RMSE آن کمتر از مدل متشابه‌ترین گره است (۵۷۶۱,۶۱ در مقابل ۴۹۵۰,۱). و در نهایت سری زمانی نرخ یورو به ریال RMSE مدل متشابه‌ترین گره و مدل گره‌های متشابه وزن‌دار تقریباً برابر است (۵۳۷۵,۹۸ و ۵۳۷۵,۹۸)، اما سایر معیارها نشان می‌دهند که هر دو مدل عملکرد مشابهی دارند. به طور خلاصه میتوان گفت مدل «گره‌های متشابه وزن‌دار» در اکثر سری‌های زمانی به جز نفت و طلا عملکرد بهتری نسبت به مدل «متشابه‌ترین گره» داشته است. هر دو مدل در پیش‌بینی سری زمانی Euro/IRR عملکرد تقریباً مشابهی دارند. برای بررسی بهبود این عملکرد به مدل سوم که پیش‌بینی به کمک گراف پدیداری متقاطع است خواهیم پرداخت.

پیش‌بینی به کمک گراف پدیداری متقاطع

در دو مدل قبلی به کمک گراف پدیداری به پیش‌بینی روند سری‌های زمانی پرداختیم و خطاهای نتایج این مدل‌ها را ارائه دادیم. حال در این قسمت می‌خواهیم به کمک گراف پدیداری متقاطع به این پیش‌بینی پردازیم. به منظور تشکیل گراف پدیداری متقاطع افزون بر سری زمانی مورد نظر جهت پیش‌بینی، به یک سری زمانی ثانویه نیز نیازمند خواهیم بود که از سری‌های زمانی ثانویه متفاوتی برای شاخص بورس اوراق بهادار از جمله نرخ سکه، نرخ دلار به ریال و نرخ یورو به ریال، قیمت جهانی نفت و طلا استفاده شده است.

بررسی دقت مدل

خطاهای حاصل از نتیجه این مدل برای پیش‌بینی، در جدول ۳ و جدول ۴ گزارش شده است. در ابتدا در جدول ۳ به بررسی خطای پیش‌بینی به کمک گراف پدیداری متقاطع در بازه های متفاوت خواهیم پرداخت. در این قسمت سری زمانی ثانویه را نرخ دلار به ریال در نظر می‌گیریم. و در جدول ۴ به ارزیابی پیش‌بینی سری زمانی شاخص در مقابل تمامی سری‌های زمانی ثانویه در کل بازه مورد بررسی، می‌پردازیم. نتایج بیانگر آن است که تمامی خطاهای پیش‌بینی شده بر اساس MAPE کاملاً قابل قبولند اما همانطور که مشاهده می‌کنید در جدول ۴ برای پیش‌بینی سری‌های زمانی شاخص در مقابل تمامی سری‌های زمانی ثانویه در کل بازه مورد بررسی تقریباً خطای یکسانی را گزارش می‌دهند.

با توجه به مقادیر RMSE و NRMSE (جدول ۴) که نشان‌دهنده آن است که خطاها در بازه‌های زمانی کوتاه‌تر کمتر هستند و با افزایش بازه زمانی، خطاهای مطلق افزایش پیدا می‌کنند، اما به نسبت، عملکرد مدل در (NRMSE) در بازه‌های طولانی‌تر کمی بهتر می‌شود. MAP و MAPE نشان می‌دهند که درصد خطا و مقدار خطای مطلق نیز با افزایش بازه زمانی افزایش پیدا کرده است. به طور کلی، این جدول نشان می‌دهد که دقت مدل در بازه‌های کوتاه‌تر بیشتر است، اما در بازه‌های زمانی طولانی‌تر، مدل دچار خطای بیشتری می‌شود.

جدول ۳. خطاهای پیش‌بینی سری زمانی شاخص به عنوان سری زمانی اصلی از طریق سری زمانی دلار به ریال به عنوان سری زمانی ثانویه به کمک گراف پدیداری متقاطع در بازه‌های زمانی متفاوت

خطا بازه زمانی	RMSE	(%) NRMSE	MAP	(%) MAPE
۳ ماهه	۱۲۰۵۷٫۳۶	۷٫۴۳	۵۶۷۴٫۰۸	۰٫۲۷
۶ ماهه	۱۳۲۵۳٫۰۳	۵٫۰۸	۸۴۶۸٫۳۳	۰٫۴
یک ساله	۲۲۵۸۳٫۴۱	۲٫۴	۱۴۴۸۲٫۹	۰٫۶۷
دو ساله	۲۰۹۲۲٫۰۵	۱٫۵۸	۱۳۹۲۶٫۴۴	۰٫۷۶
کل داده‌ها	۱۳۵۹۶٫۸۷	۰٫۵۴	۶۳۸۷٫۰۵	۰٫۷۶

در جدول ۳ مقادیر RMSE برای تمامی سری‌های ثانویه تاحدودی برابر با ۱،۳۵۶،۰۰۰ هستند، که نشان‌دهنده این است که مدل در پیش‌بینی با استفاده از هر کدام از این سری‌ها به صورت تقریبی خطایی مشابه داشته است. این می‌تواند نشان دهد که تمامی سری‌های ثانویه اهمیت کمابیش برابری در مدل پیش‌بینی شاخص اصلی دارند و سهم یکسانی در پیش‌بینی نهایی ایفا می‌کنند. با توجه به اینکه NRMSE در تمامی سری‌های ثانویه برابر با ۰٫۵۴٪ است، می‌توانیم نتیجه بگیریم که مدل به خوبی توانسته این سری‌ها را پیش‌بینی کند. نرمال بودن این خطا نشان‌دهنده این است که خطاهای مطلق (RMSE) در نسبت با دامنه داده‌های هر سری منطقی هستند و مدل به صورت کلی عملکرد قابل قبولی در پیش‌بینی این سری‌ها داشته است. MAP در محدوده ۶،۳۰۰،۰۰۰ تا ۶،۴۰۰،۰۰۰ است که باز هم نشان می‌دهد مدل با استفاده از تمامی سری‌های ثانویه عملکرد تقریباً مشابهی در خطای مطلق دارد.

MAPE که درصد خطای میانگین را نشان می‌دهد، برای همه سری‌ها بسیار پایین و در حدود ۰,۷۵٪ تا ۰,۷۶٪ است. این عدد کوچک نشان‌دهنده این است که مدل با دقت بسیار بالایی سری زمانی شاخص را پیش‌بینی کرده است.

جدول ۴. پیش‌بینی سری زمانی شاخص کل از طریق گراف پدیداری متقاطع در بازه زمانی ۱۳۹۲ تا ۱۴۰۳

خطا	RMSE	(%) NRMSE	MAP	(%) MAPE
سری زمانی ثانویه Oil	۱۳۵۶۷,۸۶	۰,۵۴	۶۳۸۸,۸۸	۰,۷۵
Gold	۱۳۵۸۴,۹۸	۰,۵۴	۶۳۹۷,۱۴	۰,۷۵
Coin	۱۳۵۰۳,۸۶	۰,۵۴	۶۳۴۱,۸۸	۰,۷۴
USD/IRR	۱۳۵۹۶,۸۷	۰,۵۴	۶۳۸۷,۰۵	۰,۷۵
EURO/IRR	۱۳۵۳۴,۷۹	۰,۵۴	۶۴۰۰,۹۹	۰,۷۶

بحث و نتیجه‌گیری

پیش‌بینی شاخص بورس از دیرباز در تمامی کشورها برای کاهش ریسک سرمایه‌گذاری و افزایش بازده از دغدغه بزرگ پژوهشگران و موسسات مالی و همچنین سرمایه‌گذاران بوده است. به علت پویایی بازار و رفتار تصادفی بازیگران آن، پیش‌بینی به صورت دقیق و با خطای کم بسیار امری پیچیده و دشوار است و نیاز به پیش‌بینی دقیق‌تر باعث شده هر روزه روش‌های متفاوتی مورد بررسی قرار گیرند. در این پژوهش ما سعی بر این داشته ایم که به کمک روش گراف پدیداری به پیش‌بینی شاخص‌های TEDPIX در سال‌های ۱۳۹۲ تا ۱۴۰۳ پرداخته و در این راستا از سری‌های زمانی قیمت نفت، نرخ دلار به ریال و نرخ یورو به ریال و سکه بهار آزادی در بازه زمانی متناظر کمک گرفته ایم.

در این پژوهش در ابتدا به مبانی نظری و پیشینه مدل به کار رفته پرداخته و سپس ابزارهای ریاضی مورد نیاز در راستای پیاده‌سازی این مدل‌ها را معرفی کردیم. در این راستا هر سری زمانی را به گراف پدیداری تبدیل کرده و به کمک مدل‌های اول تا سوم به پیش‌بینی سری‌های زمانی بیان شده در بالا پرداختیم. در مدل اول برای پیش‌بینی داده‌های آتی در گراف پدیداری از متشابه‌ترین گره به داده آخر سری زمانی کمک گرفتیم و با توجه به معادله (۱۱) مقداری برای این پیش‌بینی اختصاص دادیم. در ادامه با تعمیم مدل اول سعی در بهبود نتایج حاصله

کردیم و با توجه به معادله (۱۷) این بار نه تنها از متشابه‌ترین گره بلکه از مابقی گره‌ها متناسب با وزن آنها کمک گرفتیم و در نهایت به کمک مقدار پیش‌بینی را یافتیم. در هر دوی این مدل‌ها خطاهای RMSE، NRMSE، MAPE و MAP را برای داده‌های موجود در جدول ۱ و جدول ۲ گزارش دادیم. در مدل سوم با رهیافتی متفاوت به تشکیل گراف پدیداری متقاطع با استفاده از دو سری زمانی (سری زمانی اصلی و ثانویه) پرداخته و در ادامه همانند دو مدل قبلی مقدار آتی را پیش‌بینی کرده و خطاهای به دست آمده از این روش را در جدول ۳ و جدول ۴ گزارش کردیم. با توجه به پژوهش انجام شده و آزمون‌های صورت گرفته برای پیش‌بینی سری زمانی نشان دادیم مدل گره‌های متشابه وزن‌دارنسبت به مدل متشابه‌ترین گره در بیشتر موارد و بازه‌های زمانی مختلف توانسته است دقت بالاتری در پیش‌بینی نشان دهد و خطاهای کمتری داشته باشد. در عین حال در مدل پیش‌بینی از طریق گراف پدیداری متقاطع مدل پیش‌بینی توانسته است با استفاده از تمامی سری‌های ثانویه، خطایی تقریباً یکسان و کم تولید کند. تمامی سری‌های ثانویه به یک اندازه در بهبود دقت پیش‌بینی شاخص اصلی مؤثر بوده‌اند. در هر سه مدل با افزایش حجم داده‌های مورد بررسی، تغییر در دقت پیش‌بینی با توجه به حجم داده‌ها رخ داد.

در ادامه به پژوهشگران آتی پیشنهاد می‌گردد این مدل‌ها را در بازارهای متفاوت (بازارهای در حال توسعه، بازارهای توسعه یافته) و در بازه‌های متفاوت مورد بررسی قرار بدهند. یا به بررسی روش‌هایی بپردازند که به بهبود این مدل‌ها بیانجامد. به طور مثال با انتخاب چه سری زمانی ثانویه‌ای در مدل سوم می‌توان کمترین خطای پیش‌بینی شده را به دست آوریم. یا با چه روش‌هایی می‌توانیم وزن‌دهی به داده‌های مشابه را بهبود دهیم (مدل دوم و سوم).

References

- Asiaei Taheri, F; zomorodian, g; & Fallahshams, M. (2024). Providing a Smart Trading System Based on the Combination of Technical Analysis Indicators, Meta-Heuristic Algorithms and Neural Network in Tehran Stock Exchange. *Journal of Securities Exchange*, 17(65), 133-152. <https://doi.org/10.22034/jse.2023.12263.2161>. (In Persian).
- Bao, W; Yue, J; & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PloS one*, 12(7), e0180944.
- Box, G. E; Jenkins, G. M; Reinsel, G. C; & Ljung, G. M. (2008). *Time Series Analysis: Forecasting and Control*. Wiley. Hoboken, NJ.
- Büyükaşahin, Ü. Ç; & Ertekin, Ş. (2019). Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition. *Neurocomputing*, 361, 151-163.
- Chen, D. R; Liu, C; Zhang, Y. C; & Zhang, Z. K. (2019). Predicting financial extremes based on weighted visual graph of major stock indices. *Complexity*, 2019, 1-17.
- Chimmula, V. K. R; & Zhang, L. (2020). Time series forecasting of COVID-19 transmission in Canada using LSTM networks. *Chaos, Solitons & Fractals*, 135, 109864.
- Chu, C; Hu, X; Shen, C; Li, T; Boccaletti, S; Shi, L; & Wang, Z. (2019). Self-organized interdependence among populations promotes cooperation by means of coevolution. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 29(1), 013139.
- Deb, C; Zhang, F; Yang, J; Lee, S. E; & Shah, K. W. (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, 902-924.
- Demertzis, K; Tsiotas, D; & Magafas, L. (2020). Modeling and forecasting the COVID-19 temporal spread in Greece: An exploratory approach based on complex network defined splines. *International Journal of Environmental Research and Public Health*, 17(13), 4693.
- Hajirahimi, Z; & Khashei, M. (2019). Hybrid structures in time series modeling and forecasting: A review. *Engineering Applications of Artificial Intelligence*, 86, 83-106.
- Hajirahimi, Z; & Khashei, M. (2023). Hybridization of hybrid structures for time series forecasting: A review. *Artificial Intelligence Review*, 56(2), 1201-1261.
- Holt, C. C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*, 20(1), 5-10. (In Persian).
- Hu, Y; & Xiao, F. (2022). A novel method for forecasting time series based on directed visibility graph and improved random walk. *Physica A: Statistical Mechanics and its Applications*, 594, 127029.
- Iacovacci, J; & Lacasa, L. (2019). Visibility graphs for image processing. *IEEE transactions on pattern analysis and machine intelligence*, 42(4), 974-987.
- Kashima, H; Kato, T; Yamanishi, Y; Sugiyama, M; & Tsuda, K. (2009, April). Link propagation: A fast semi-supervised learning algorithm for link

- prediction. In Proceedings of the 2009 SIAM international conference on data mining (pp. 1100-1111). *Society for Industrial and Applied Mathematics*.
- Koushki, A; Osoolian, M. & Sadeghi Sharif, S. (2023). An uncertainty measure based on Pearson correlation as well as a multiscale generalized Shannon-based entropy with financial market applications. *International Journal of Nonlinear Sciences and Numerical Simulation*, 24(5), 1821-1839. <https://doi.org/10.1515/ijnsns-2021-0096>.
- Lacasa, L; Luque, B; Ballesteros, F; Luque, J; & Nuno, J. C. (2008). From time series to complex networks: The visibility graph. *Proceedings of the National Academy of Sciences*, 105(13), 4972-4975.
- Lai, J. W; Chang, J; Ang, L. K; & Cheong, K. H. (2020). Multi-level information fusion to alleviate network congestion. *Information Fusion*, 63, 248-255.
- Liu, W; & Lü, L. (2010). Link prediction based on local random walk. *Europhysics Letters*, 89(5), 58007.
- Mao, S; & Xiao, F. (2019). Time series forecasting based on complex network analysis. *IEEE Access*, 7, 40220-40229.
- Mao, S; Deng, Y; & Pelusi, D. (2020). Alternatives selection for produced water management: A network-based methodology. *Engineering Applications of Artificial Intelligence*, 91, 103556.
- Mehraban, S; Shirazi, A. H; Zamani, M; & Jafari, G. R. (2013). Coupling between time series: A network view. *Europhysics Letters*, 103(5), 50011.
- Morid, M. A; Sheng, O. R. L; & Dunbar, J. (2023). Time series prediction using deep learning methods in healthcare. *ACM Transactions on Management Information Systems*, 14(1), 1-29.
- Osoolian, M; & Koushki, A. (2020). Investigating the Crisis Forecasting Ability of the Cumulative Residual Entropy Measure by using Logistic Map Simulation Data and Tehran Stock Exchange Overall Index. *Financial Management Perspective*, 10(31), 9-27. doi: 10.52547/jfmp.10.31.9. (In Persian).
- Ozcan, A; & Oguducu, S. G. (2019). Multivariate time series link prediction for evolving heterogeneous network. *International Journal of Information Technology & Decision Making*, 18(01), 241-286.
- 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(4), 1-23. <https://doi.org/10.22051/jfm.2017.12410.1175>. (In Persian).
- Ranjbar Navi, R; Arshadi, A; & Chenari, H. (2021). Prediction of Stock Price Index Using Gray Model. *Journal of Securities Exchange*, 14(53), 115-137. <https://doi.org/10.22034/jse.2020.11152.1385> (In Persian).
- Rezazadeh, ALi. "The impact of macroeconomic variables on Tehran stock market returns volatility: GARCH-X approach." *Quarterly Journal of Applied Theories of Economics* 3.2 (2016): 121-136. (In Persian).
- Sadaei, H. J; e Silva, P. C. D. L; Guimaraes, F. G; & Lee, M. H. (2019). Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series. *Energy*, 175, 365-377.

- Solymanisarvestani, s; davoodi, s. m. r; & Kheradmand, a. (2024). Optimal Daily Scalping Trading Portfolio Based on Interval-Valued Prediction with Vector Autoregression Approac. *Journal of Securities Exchange*, 17(65), 69-86. <https://doi.org/10.22034/jse.2024.12118.2073>. (In Persian).
- Swanson, D. A. (2015). On the relationship among values of the same summary measure of error when used across multiple characteristics at the same point in time: an examination of MALPE and MAPE. *Review of Economics and Finance*, 5(1).
- Wang, K. W; Deng, C; Li, J. P; Zhang, Y. Y; Li, X. Y; & Wu, M. C. (2017). Hybrid methodology for tuberculosis incidence time-series forecasting based on ARIMA and a NAR neural network. *Epidemiology & Infection*, 145(6), 1118-1129.
- Wang, L; Wang, Z; Qu, H; & Liu, S. (2018). Optimal forecast combination based on neural networks for time series forecasting. *Applied soft computing*, 66, 1-17.
- Wang, M; Xu, H; Tian, L; & Stanley, H. E. (2018). Degree distributions and motif profiles of limited penetrable horizontal visibility graphs. *Physica A: Statistical Mechanics and its Applications*, 509, 620-634.
- Wei, Zhongyuan. A SVM approach in forecasting the moving direction of Chinese stock indices. Lehigh University, 2012.
- Wen, T; Song, M; & Jiang, W. (2018). Evaluating topological vulnerability based on fuzzy fractal dimension. *International Journal of Fuzzy Systems*, 20, 1956-1967.
- Ye, Y; Hang, X. R; Koh, J. M; Miszczak, J. A; Cheong, K. H; & Xie, N. G. (2020). Passive network evolution promotes group welfare in complex networks. *Chaos, Solitons & Fractals*, 130, 109464.
- Zhan, T; & Xiao, F. (2021). A novel weighted approach for time series forecasting based on visibility graph. arXiv preprint arXiv:2103.13870.
- Zhang, R; Ashuri, B; & Deng, Y. (2017). A novel method for forecasting time series based on fuzzy logic and visibility graph. *Advances in Data Analysis and Classification*, 11, 759-783.
- Zou, Y; Donner, R. V; Marwan, N; Donges, J. F; & Kurths, 2. (2019). Complex network approaches to nonlinear time series analysis. *Physics Reports*, 787, 1-97.