



Securities & Exchange Organization, Research, Development & Islamic Studies (RDIS)
Journal of Securities and Exchange, Fall 2022, V. 15, No.59, pp. 245-268

Modeling the Prediction of Stock Market Jumps Based on the Recurrent Neural Network and Deep Learning¹

Maryam Sohrabi², Seyed Mozaffar Mirbargkar³,
Ebrahim Chirani⁴, Sina Kheradyar⁵

Received: 2021/04/23

Accepted: 2021/10/17

Research Paper

Abstract

Predicting crises and price jumps in the stock market and based on different models has been growing over the last decade. Due to the presence of big data, this issue has led to the growth of developments in the field of machine learning and deep learning models. Due to the importance of this issue this study examined the ability of different machine learning models to predict the jumps in the total index of the Tehran Stock Exchange during the period 2013 to 2020. For this purpose, first stock market jumps were extracted based on the ARJI-GARCH approach and then these jumps were predicted by considering the possible effective variables including global and domestic markets. The prediction results of 1-, 3-, and 6-day periods for the out-of-sample period show that the machine learning method based on the long short-term memory (LSTM) network, a recurrent neural network, has a better result than other models.

Key Words: Stock Market Jumps, Forecasting, Machine learning, Recurrent Neural Networks.

JEL Classification: G17-G170-G150.

-
1. DOI: 10.22034/JSE.2021.11655.1762
 2. Ph.D. Student in Financial Engineering, Department of Business Management, Rasht Branch, Islamic Azad University, Rasht, Iran. (sohrabi.1446@gmail.com)
 3. Assistant Professor, Department of Business Management, Rasht Branch, Islamic Azad University, Rasht, Iran. (Corresponding Author). (mirbargkar@yahoo.com).
 4. Assistant Professor, Department of Business Management, Rasht Branch, Islamic Azad University, Rasht, Iran. (chirani@iaurasht.ac.ir).
 5. Assistant Professor, Department of Accounting, Rasht Branch, Islamic Azad University, Rasht, Iran. (sinakheradyar@gmail.com).

مدل سازی پیش بینی جهش های شاخص بازار سهام بر اساس رویکرد شبکه عصبی بازگشتی یادگیری عمیق^۱

مریم سهرابی^۲، سید مظفر میربرگ کار^۳، ابراهیم چیرانی^۴، سینا خریدار^۵

تاریخ دریافت: ۱۴۰۰/۰۲/۰۳

تاریخ پذیرش: ۱۴۰۰/۰۷/۲۵

مقاله پژوهشی

چکیده

هدف از انجام این پژوهش بررسی دقت پیش بینی جهش های شاخص سهام بر اساس روش های مختلف یادگیری ماشین در بورس اوراق بهادار تهران است. برای رسیدن به این هدف، در گام نخست جهش های شاخص کل بورس اوراق بهادار تهران در دوره ۱۳۹۲ تا ۱۳۹۹ بر اساس رویکرد ARJI-GARCH استخراج شد. در گام بعدی، با بهره گیری از رویکردهای جنگل تصادفی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی بازگشتی استوار بر یادگیری عمیق به پیش بینی جهش های شاخص سهام پرداخته شد. بدین منظور، از ۸۰ درصد کل داده ها به عنوان دوره یادگیری ماشین (درون نمونه) و مابقی داده ها به عنوان دوره آزمون (خارج از نمونه) استفاده شده است. نتایج پیش بینی ۱، ۳ و ۶ روزه برای دوره آزمون (خارج از نمونه) نشان می دهد که روش یادگیری ماشین استوار بر شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت (LSTM) نتیجه بهتری نسبت به سایر مدل های مورد بررسی برای هر سه افق پیش بینی داشته است.

واژه های کلیدی: جهش بازار سهام، پیش بینی، یادگیری ماشین، شبکه عصبی بازگشتی.

طبقه بندی موضوعی: G17-G170-G150.

DOI: 10.22034/JSE.2021.11655.1762

۲. دانشجوی دکتری، گروه مدیریت بازرگانی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران.

۳. استادیار، گروه مدیریت بازرگانی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران. (نویسنده مسئول). (mirbargkar@yahoo.com)

۴. استادیار، گروه مدیریت بازرگانی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران.

۵. استادیار، گروه حسابداری، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران.

مقدمه

یکی از مسائل کلاسیک در بازار سهام، پیش‌بینی قیمت سهام که در چند دهه اخیر مورد بحث و پژوهش قرار گرفته است. ناشناخته بودن عوامل تأثیرگذار بر تغییرات قیمت سهام همواره دلیلی برای روی آوردن به پیش‌بینی قیمت سهام است. از این رو، متخصصان بازار سرمایه، سالیان متمادی به مطالعه بازار و شناسایی الگوهای مختلف برای پیش‌بینی پرداخته‌اند. مطابق با فرضیه بازار کارا، نمی‌توان قیمت سهام را پیش‌بینی کرد، چرا که قیمت سهام به صورت تصادفی رفتار می‌کند. اما تحلیل‌گران فنی معتقدند که بیشتر اطلاعات مربوط به سهام در قیمت‌های اخیر منعکس می‌شود و بنابراین اگر روند تغییرات مشاهده و دنبال شود، قیمت‌ها را می‌توان پیش‌بینی کرد. افزون بر این، تحرکات بازار سهام تحت تأثیر بسیاری از عوامل کلان اقتصادی مانند رویدادهای سیاسی، شرایط کلی اقتصادی، شاخص بازار کالا، نرخ بهره بانکی، نرخ ارز، روند سایر بازارهای مالی و بین‌المللی، انتظارات سرمایه‌گذاران، انتخاب سرمایه‌گذاران نهادی، تحرکات دیگر بازارهای سهام، روانشناسی سرمایه‌گذاران و غیره است (پاتل و همکاران^۱، ۲۰۱۵). در حال حاضر مطالعات مختلفی همچون کریستین و رونالدو^۲ (۲۰۰۹)، مارکوات و همکاران^۳ (۲۰۰۹)، ژیانو و همکاران^۴ (۲۰۱۳)، سرولوروی و همکاران^۵ (۲۰۱۵)، چیانگ و همکاران^۶ (۲۰۱۶)، ژونگ و اینک^۷ (۲۰۱۷) و کیم و چانگ^۸ (۲۰۱۸) رفتار تصادفی قیمت سهام را رد کرده‌اند. همچنین کاربرد هوش مصنوعی در مسائل مالی موجب تقویت این نظریه شده که بازار ممکن است همیشه به طور کامل کارا نباشد و بتوان قیمت‌های آینده را با بهره‌گیری از داده‌های تاریخی و تکنیک‌های مختلف پیش‌بینی کرد. از سوی دیگر، با توجه به اینکه قیمت سهام مشتق از عملکرد بخش واقعی اقتصاد است، اقتصادهای ملی متأثر از عملکرد قیمت سهام در بورس اوراق بهادار بوده و یکی از مهمترین اطلاعات در بازار بورس اوراق بهادار برای سرمایه‌گذاران، سیاست‌مداران و فعالان اقتصادی به شمار می‌آید. بنابراین پیش‌بینی شاخص قیمت سهام افزون بر اینکه موضوع چالشی در بازار سهام است، یکی از موضوع‌های جذاب و

1. Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015)
2. Christiansen and Ranaldo (2009)
3. Markwat et al. (2009)
4. Xiao, Y., Xiao, J., Lu, F., & Wang, Sh. (2013)
5. Cervelló- Royo, Guijarroa, and Michniukab (2015)
6. Chiang, Enke, Wu, and Wang (2016)
7. Zhong and Enke (2017)
8. Kim and Chang (2018)

مورد علاقه برای پژوهش نیز به شمار می آید. بر این اساس، هدف اصلی این پژوهش پیش‌بینی جهش‌های شاخص کل بورس اوراق بهادار تهران با استفاده از روش یادگیری ماشین و بررسی توانایی مدل‌های یادگیری عمیق و شبکه عصبی بازگشتی است.

برای پیش‌بینی بازار سهام به کمک داده‌های تاریخی، روش‌های مختلفی وجود دارد. در یک طبقه‌بندی، این روش‌ها در دو گروه خطی و غیرخطی قرار می‌گیرند و در نوع دیگر، به روش‌های یادگیری ماشین و آماری، دسته‌بندی می‌شوند. اما دسته‌بندی مناسب، گروه‌بندی آنها به روش‌های هوشمند و کلاسیک است (پاتل و همکاران، ۲۰۱۵). در روش‌های پیش‌بینی کلاسیک، فرض بر این است که مقادیر آینده قیمت، روند خطی مقادیر گذشته را دنبال می‌کند و مدل‌های رگرسیون و ARMA، GARCH و ماشین‌های بردار پشتیبان و منطق فازی در این دسته جای دارند. شبکه‌های عصبی و مدل‌های یادگیری جمعی در دسته روش‌های هوشمند قرار دارد (کوالکاتنه و همکاران، ۲۰۱۶). نتیجه مقایسه‌ها نشان داده است که روش‌های هوشمند با چیرگی بر محدودیت‌های موجود در مدل‌های خطی در مقایسه با روش‌های کلاسیک، برای استخراج مدل از داده‌ها توانایی بهتر و برای پیش‌بینی، دقت بیشتری دارند (آدبی، ادمووی و آیو، ۲۰۱۴).

در ادامه به روش‌شناسی پژوهش، اشاره خواهد شد و پس از مروری بر مبانی نظری و تجربی مبحث یاد شده، یافته‌های تجربی حاصل از پژوهش حاضر ارائه خواهد شد و در انتها نتیجه‌گیری و بحث موضوعی مورد بررسی قرار خواهد گرفت.

پیشینه نظری پژوهش

بازارهای مالی نقش مهمی در سازماندهی اقتصادی جامعه مدرن ایفا می‌کنند. بی‌تردید امروزه بیشترین مقدار سرمایه در جهان از طریق بازارهای بورس مبادله می‌شود. اقتصادهای ملی نیز متأثر از عملکرد قیمت سهام در بازار بورس است که در چگونگی سرمایه‌گذاری، اندازه‌گیری ریسک، پوشش ریسک و سیاست‌گذاری به طور مؤثر مورد استفاده قرار می‌گیرد. بنابراین پیش‌بینی قیمت سهام نه تنها یک موضوع چالش برانگیز، بلکه مورد علاقه فعالان این بخش در راستای کنترل ریسک و افزایش بازدهی است. از سوی دیگر، برآورد و پیش‌بینی

1. Cavalcante, R. C., Brasileiro, R. C., Souza, V. L.F., Nobrega, J. P., & Oliveira, A. L.I. (2016)
2. Adebiji, A. A., Adewumi, A.O., & Ayo, C. K. (2014)

جهش‌های شاخص بورس یکی از مهمترین موضوعات بازارهای مالی دنیا است. جهش به عنوان یک عامل مؤثر در تعیین ریسک سرمایه‌گذاری، می‌تواند نقش مهمی در تصمیم‌گیری سرمایه‌گذاران ایفا کند. یک تخمین مناسب از جهش و تلاطم شرطی در یک دوره سرمایه‌گذاری نقطه آغازین بسیار مهمی در کنترل ریسک سرمایه‌گذاری است. بر این اساس، موضوع پیش‌بینی شاخص سهام و جهش‌های شاخص سهام به ویژه در کشورهای در حال توسعه، به منظور مدیریت صحیح بورس اوراق بهادار برای رسیدن به توسعه پایدار اهمیت به سزایی دارد. بنابراین فعالان در بازار سرمایه نیازمند ابزارهای لازم و قابل اعتماد برای پیش‌بینی روند قیمت سهام هستند تا از این طریق سرمایه‌گذاری با ریسک کم و بازدهی مناسب را داشته باشند. در این راستا، تا دهه ۱۹۸۰ نظریه‌های مطرح شده به خوبی تعیین‌کننده قیمت سهام در بازار بودند تا اینکه تحولات بازار بورس نیویورک در سال ۱۹۸۷ اعتبار فرضیه‌های بازار کارا با توجه به شواهد بدست آمده را مورد پرسش قرار دادند. در دهه ۱۹۹۰ و بعد از آن، پژوهشگران در این زمینه برای پیش‌بینی قیمت سهام با توجه به بحران‌های مالی و وجود سرایت در بین بازارهای مالی، در تلاش برای طراحی مدل‌های مختلف خطی و غیرخطی به منظور پیش‌بینی قیمت سهام بوده‌اند. بسیاری از این مطالعات نیز تأثیر عوامل مختلف سیاسی، اقتصادی، روانی و سرایت بین سایر بازارها را در پیش‌بینی دقیق‌تر قیمت سهام مؤثر دانسته‌اند (پاتل و همکاران، ۲۰۱۵). در این راستا همانطور که در بخش قبلی اشاره شد، پیش‌بینی متغیرهای مالی با استفاده از تکنیک‌های پیشرفته مدل‌سازی، یکی از مباحث بسیار گسترده در ادبیات دانشگاهی بوده است. این موضوع با توجه به حضور کلان داده‌ها، موجب رشد تحولات در زمینه یادگیری ماشین شده است. مطالعات نشان می‌دهد که روش‌های جدیدتر و استفاده از مدل‌های غیرخطی و بهره‌گیری از هوش مصنوعی در این زمینه عملکرد بهتری به نسبت روش‌های سنتی دارد (پاتل و همکاران، ۲۰۱۵). در این طبقه‌بندی، در حال حاضر رویکردهای ماشین بردار پشتیبان (SVM)، شبکه عصبی مصنوعی و روش‌های استوار بر یادگیری ماشین و یادگیری عمیق از توانمندترین مدل‌های مورد استفاده در زمینه پیش‌بینی قیمت سهام و بحران‌های مالی به شمار می‌آیند.

مبانی تجربی پژوهش

در سالیان گذشته، مطالعات در زمینه یادگیری ماشین دارای یک روند افزایشی بوده است که مرتب با توسعه تکنیک‌های ریاضیاتی کامپیوتری در حال پیشرفت است. در بخشی از ادبیات

شکل گرفته پیرامون این موضوع، مطالعات مختص به رویکردهای یادگیری ماشین است که در ادامه به تفکیک، مطالعات داخلی و خارجی بیان شده است.

فلاح پور و علی پور (۱۳۹۳)، به پیش‌بینی شاخص کل سهام بورس اوراق بهادار تهران با استفاده از مدل‌های مختلف شبکه‌های عصبی مبتنی بر تجزیه موجک پرداخته‌اند. نتایج این پژوهش نشان می‌دهد، عملکرد شبکه عصبی موجکی در پیش‌بینی شاخص سهام سطح خطای کمتری دارد و از شبکه عصبی بهتر است.

راعی و همکاران (۱۳۹۵)، در پژوهش خود، به منظور افزایش دقت پیش‌بینی شاخص بورس اوراق بهادار تهران، ترکیبی از روش‌های آماری و هوش مصنوعی به کار برده‌اند. مدل اصلی پیش‌بینی در این پژوهش، رگرسیون بردار پشتیبان بهینه شده به وسیله الگوریتم حرکت تجمعی ذرات بوده است. نتایج به دست آمده نشان داد که پیش‌پردازش روی داده‌ها و استفاده از رویکردهای یاد شده، خطای پیش‌بینی مدل را به طور چشمگیری کاهش داده است.

باجلان و همکاران (۱۳۹۵)، یک مدل پیش‌بینی بر اساس روش ماشین بردار پشتیبان تعدیل شده با استفاده از وزن‌دار کردن تابع جریمه مدل و با توجه به حجم معاملات واقعی روزانه به منظور افزایش دقت پیش‌بینی نوسان‌های کوتاه‌مدت در بازار سهام و دستیابی به راهبرد معاملاتی بهینه، ارائه داده‌اند. نتایج نشان می‌دهد مدل ماشین بردار پشتیبان وزن‌دهی شده، همراه با روش انتخاب ویژگی هیبرید پیشنهاد شده، میزان دقت پیش‌بینی را به میزان چشمگیری افزایش داده و نیز نتایج راهبرد معاملاتی پیشنهاد شده را نسبت به راهبردهای رقیب، هم از دیدگاه میزان بازده کلی و هم از دیدگاه میزان بیشینه ضرر در طول دوره سرمایه‌گذاری، بهبود می‌بخشد.

فقیهی‌نژاد و مینایی (۱۳۹۷)، به ارائه یک مدل هوشمند برای پیش‌بینی رفتار بازار سهام پرداخته‌اند. این مقاله، برای افزایش دقت از مدلی بر پایه الگوریتم‌های یادگیری جمعی با مدل‌های پایه شبکه‌های عصبی، استفاده می‌کند. نتایج معیارهای ارزیابی روی داده‌های واقعی قیمت سهام نشان می‌دهد، مدل پیشنهاد شده در مقایسه با سایر روش‌ها، با دقت بیشتری می‌تواند بر نوسان‌های بازار غلبه کرده و به عنوان روش قابل اطمینان و عملی در بازارهای سهام به کار گرفته شود.

دهقانی و همکاران (۱۳۹۸)، به بررسی سودمندی الگوریتم‌های هوشمند مختلف در حوزه یادگیری ماشین برای پیش‌بینی سری‌های زمانی در بازارهای مالی پرداخته‌اند. نتایج تجربی نشان می‌دهند که ویژگی‌های فنی منتخب توسط روش پیشرو، مؤثرترین و نیز بهترین مقادیر برای

پارامترهای الگوریتم‌های یادگیری موردنظر را می‌یابند. همچنین نتایج، گویای این موضوع است که بکارگیری ویژگی‌های فنی منتخب، به عنوان ورودی دو الگوریتم ماشین بردار پشتیبان و ماشین پرسپترون چند لایه، یک پیش‌بینی با حداقل خطا و دقت بالا را حاصل می‌کند. در بخش مطالعات خارجی نیز مطالعات در زمینه پیش‌بینی قیمت سهام بر اساس مدل‌های یادگیری ماشین در دهه اخیر روند چشمگیری داشته است که در ادامه به مرور برخی از آنها پرداخته شده است.

وانگ^۱ (۲۰۱۸)، شبکه عصبی پیشخور را با بهینه‌سازی تجزیه شیمیایی باکتری^۲ (IBCO) ترکیب کرد. وی توانایی رویکرد پیشنهادی خود را در پیش‌بینی شاخص سهام برای کوتاه‌مدت (یک روزه) و بلندمدت (۱۵ روزه) برای بازار سهام آمریکا و چین مورد استفاده قرار داده و نشان داد این روش از رویکردهای ساده شبکه عصبی و همچنین رویکردهای سری زمانی عملکرد بهتری را داشته است.

ژیائو و همکاران (۲۰۱۳)، بر اساس شبکه‌های عصبی مصنوعی (ANNs)، ماشین‌های بردار پشتیبانی (SVM) و جنگل‌های تصادفی (RFs)، به پیش‌بینی بحران مالی پرداختند. نتایج این بررسی نشان داد که رویکرد شبکه عصبی مصنوعی در شرایط بهتری به نسبت سایر مدل‌های مورد بررسی است.

پاتل و همکاران (۲۰۱۵)، به پیش‌بینی شاخص سهام نیویورک و همچنین شاخص S&P500 برای یک دوره ۱۰ ساله بر اساس مدل‌های مختلف یادگیری ماشین همچون جنگل تصادفی، ماشین بردار پشتیبان و شبکه عصب مصنوعی پرداختند. نتایج بررسی آنها نشان‌دهنده این واقعیت است که مدل شبکه عصبی مصنوعی (ANN) خطای کمتری نسبت به سایر رویکردهای مورد استفاده داشته است.

ازدکین و همکاران^۳ (۲۰۱۶)، هم بر پیش‌بینی قیمت درون روز سهام تمرکز کردند. آنها در مطالعه خود سیستم‌های استنتاج عصبی فازی تطبیقی، شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبانی را مورد بررسی قرار داده و نشان دادند که روش شبکه عصبی-فازی با خطای کمتری قیمت سهام را پیش‌بینی می‌کند.

1. Wang, Y. (2018)

2. Bacterial Chemotaxis Optimization

3. Oztekin, Kizilaslan, Freund, and Iseri (2016)

چاتزیس و همکاران^۱ (۲۰۱۸) به بررسی و پیش‌بینی بحران مالی در بازار سهام با استفاده از رویکردهای مختلف یادگیری ماشین و همچنین یادگیری عمیق پرداخته‌اند. نتایج این پژوهش نشان می‌دهد که رویکرد شبکه‌های عصبی مصنوعی عمیق به نسبت سایر روش‌ها در وضعیت بهتری در پیش‌بینی قرار دارد.

کیم و چانگ (۲۰۱۸) برای پیش‌بینی نوسان قیمت سهام، یک سری مدل‌های ترکیبی از حافظه کوتاه‌مدت (LSTM) و GARCH را پیشنهاد داده و بررسی می‌کنند. به طوری که نتایج گویای این واقعیت است که این مدل‌ها به کمترین خطاهای پیش‌بینی منجر می‌شوند.

نوا سلمی^۲ (۲۰۲۰)، در مقاله خود به پیش‌بینی بازده روزانه شاخص S&P 500 با استفاده از انواع روش‌های مختلف یادگیری ماشین پرداخته است. نتایج نشان می‌دهد روش‌های یادگیری ماشین توانایی بهتری به نسبت رویکرد سنتی در پیش‌بینی سری زمانی بازدهی دارد. ضمن آنکه تمام روش‌های یادگیری ماشین در نظر گرفته شده در مقایسه با راهبرد خرید و نگهداری سهام در شبیه‌سازی معاملات در دنیای واقعی، بهتر عمل می‌کنند. در این بین، ماشین استوار بر رویکرد گرادیان از نظر معیارهای ارزیابی آماری و اقتصادی دارای عملکرد برتری بوده است.

دووان و همکاران^۳ (۲۰۲۱)، به بررسی توانایی مدل‌های یادگیری ماشین و روش‌های سنتی سری زمانی در پیش‌بینی متغیرهای کلان اقتصادی کشور چین پرداخته‌اند. نتایج بررسی و توانایی مدل‌های مختلف برای دوره خارج از نمونه نشان‌دهنده توانایی بهتر رویکرد یادگیری ماشین به نسبت مدل‌های سنتی بوده است.

مقصود و همکاران^۴ (۲۰۲۱)، در مطالعه خود به پیش‌بینی شاخص قیمت سهام کشورهای توسعه یافته، نوظهور و در حال توسعه بر اساس روش‌های یادگیری عمیق و استفاده از داده‌های اقتصادی، سیاسی و متغیرهای اجتماعی پرداخته‌اند. نتایج بررسی دوره خارج از نمونه گویای این واقعیت است که مدل‌های یادگیری عمیق عملکرد بهتری دارند.

با توجه به موارد طرح شده در بالا از پیشینه موجود به راحتی می‌توان دریافت که موضوع پیش‌بینی بر اساس یادگیری ماشین و یادگیری عمیق در بازار سهام از درجه اهمیت بالایی

1. Chatzis, S. P., Siakoulis, V., Petropoulos, A., Stavroulakis, E., & Vlachogiannakis, N. (2018)

2. Nevaselmi (2020)

3. Duan et al (2021)

4. Maqsood (2021)

برخودار است. بر این اساس، در این پژوهش عملی - پژوهشی، برای نخستین بار در داخل کشور، به پیش‌بینی بازار سهام و تبیین و گسترش مدل‌سازی بر اساس یادگیری عمیق پرداخته شده است.

روش‌شناسی پژوهش

۱-۴- مدل‌سازی جهش‌های بازار

در گام اول برای برآورد جهش‌های شاخص کل بورس ارواق بهادر تهران، مدل ارائه شده با توجه به مطالعات صورت گرفته از گسترش مدل ارائه شده در پژوهش‌های چایم و لاورینی^۱ (۲۰۱۸) استفاده شده است. با این تفاوت که در این زمینه برای مدل شدت جهش از رویکرد معرفی شده وانگ^۲ (۲۰۱۸) استفاده شده است.

در ادبیات نظری، مدل جهش دارای دو بخش کلی است. بخش اول که واریانس شرطی است و از مدل GARCH قابل برآورد خواهد بود. اما بخش دوم، رخداد غیرمنتظره‌ای را نشان می‌دهد که موجب تلاطم ناگهانی می‌شود. این جزء، دارای میانگین شرطی صفر است، یعنی سرمایه‌گذار با اطلاعات دوره قبل قادر به پیش‌بینی جهش نیست، بنابراین جهش‌ها کاملاً غیرمنتظره هستند. توزیع جهش‌ها، بواسون با پارامتر λ_t در نظر گرفته می‌شود.

مقدار جهش شرطی به صورت $I_t = \sum_{k=1}^{n_t} \pi_{t,k}$ دارای توزیع نرمال با میانگین θ و واریانس δ^2 است. پس جهش‌ها به طور کامل غیرمنتظره هستند. همانطور که بیان شد، توزیع جهش‌ها، بواسون با پارامتر λ_t در نظر گرفته می‌شود. اگر n_t تعداد جهش‌های رخ داده در بازه زمانی $t-1$ تا t باشد، آنگاه چگالی شرطی n_t به صورت زیر است:

$$P(n_t = j | \phi_{t-1}) = \exp(-\lambda_t) \lambda_t^j / j! \quad (1)$$

فرض می‌کنیم پارامتر شدت λ_t به طور شرطی در طول زمان تغییر می‌کند. از خواص توزیع بواسون می‌دانیم که:

$$E(n_t = j | \phi_{t-1}) = \sum_{j=0}^{\infty} j P(n_t = j | \phi_{t-1}) = \lambda_t \quad (2)$$

$$\text{Var}(n_t = j | \phi_{t-1}) = \lambda_t$$

-
1. Chaim, Pedro, and Márcio P. Laurini. (2018)
 2. Wang, Y. (2018)

همچنین فرض می‌کنیم پارامتر شدت جهش λ_t دارای رابطه خودرگرسیون به صورت معادله (۳) است.

$$\lambda_t = \lambda_0 + \rho\lambda_{t-1} + \gamma\xi_{t-1} \quad (3)$$

لازم به بیان است در این بررسی، $\lambda_t > 0$ و $\lambda_0 > 0$ و $\rho > 0$ هستند. ξ_{t-1} پسماند شدت جهش است که به صورت زیر محاسبه می‌شود.

$$\xi_{t-1} = E[n_{t-1}|I_{t-1}] - \lambda_{t-1} = \sum_{j=0}^{\infty} jP(n_{t-1} = j|I_{t-1}) - \lambda_{t-1} \quad (4)$$

یعنی ξ_{t-1} تغییر در پیش‌بینی شرطی اقتصادسنجی n_{t-1} را نشان می‌دهد هنگامی که مجموعه اطلاعات از زمان $t-2$ تا $t-1$ به روز می‌شود. به این ترتیب:

$$E(\xi_t | \Phi_{t-1}) = 0 \quad (5)$$

یعنی ξ_t نسبت به اطلاعات Φ_{t-1} یک دنباله مارتینگلی است و دارای میانگین و کوواریانس زیر است:

$$E(\xi_t) = 0 \quad (6)$$

$$\text{Cov}(\xi_t, \xi_{t-i}) = 0$$

$$E(n_{t-1} | \Phi_{t-2}) = \lambda_{t-1}$$

بنابراین:

$$\xi_{t-1} \equiv E(n_{t-1} | \Phi_{t-1}) - \lambda_{t-1} = \left[\sum_{j=0}^{\infty} jP(n_{t-1} = j | \Phi_{t-1}) \right] - \lambda_{t-1} \quad (7)$$

در اینجا $E(n_{t-1} | \Phi_{t-1})$ تعداد مورد انتظار جهش‌های رخ داده در بازه زمانی $t-2$ تا $t-1$ با دانستن بازه دوره $t-1$ است و λ_{t-1} انتظار شرطی ما از تعداد جهش‌های n_{t-1} با داشتن مجموعه اطلاعات Φ_{t-2} است.

اندازه k امین جهش رخ داده در دوره $t-1$ تا t را با π_{tk} نشان می‌دهیم، که در آن $0 \leq k \leq n_t$. در این مدل فرض می‌شود که اندازه جهش π_{tk} از یک توزیع نرمال با میانگین θ_t و واریانس δ_t^2 پیروی می‌کند. به این ترتیب، اندازه جهش تجمعی J_t در بازه زمانی $t-1$ تا t برابر است با مجموع اندازه تمام جهش‌های رخ داده در بازه زمانی $t-1$ تا t ، یعنی:

$$J_t = \sum_{k=1}^{n_t} \pi_{tk} \quad (8)$$

از طرفی، تعداد مورد انتظار جهش‌های رخ داده در دوره $t-1$ تا t برابر λ_t و اندازه مورد انتظار هر جهش رخ داده برابر θ_t است در نتیجه:

$$E(J_t | \phi_{t-1}) = \theta_t \lambda_t \quad (9)$$

$$\varepsilon_t = \sum_{k=1}^{n_t} \pi_{tk} - \theta_t \lambda_t \quad (10)$$

و در نتیجه:

$$E(\varepsilon_t | \phi_{t-1}) = \theta_t \lambda_t - \theta_t \lambda_t \quad (11)$$

بر پایه فرمول‌های بالا خواهیم داشت:

$$\lambda_t = \lambda_0 + (\rho - \gamma)\lambda_{t-1} + \gamma E(n_{t-1} | \phi_{t-1}) \quad (12)$$

اگر $f(R_t | n_t = j, \phi_{t-1})$ چگالی شرطی بازده شاخص باشد به شرطی که j جهش رخ داده و مجموعه اطلاعات ϕ_{t-1} در دسترس باشد، با استفاده از تابع چگالی بالا و قاعده بیز خواهیم داشت:

$$f(R_t | n_t = j, \phi_{t-1}) = P(n_t = j | R_t, \phi_{t-1}) * \frac{P(R_t | \phi_{t-1})}{P(n_t = j | \phi_{t-1})} \quad (13)$$

از طرفی:

$$P(n_t = j | R_t, \phi_{t-1}) = P(n_t = j | \phi_t) \quad (14)$$

در نتیجه احتمال رخ دادن j جهش در زمان t را به صورت زیر بدست می‌آوریم:

$$P(n_t = j | \phi_t) = \frac{f(R_t | n_t = j, \phi_{t-1}) P(n_t = j | \phi_{t-1})}{P(R_t | \phi_{t-1})} \quad (15)$$

بنابراین:

$$\sum_{j=0}^{\infty} P(n_t = j | \phi_t) = \sum_{j=0}^{\infty} \frac{f(R_t | n_t = j, \phi_{t-1}) P(n_t = j | \phi_{t-1})}{P(R_t | \phi_{t-1})} \quad (16)$$

حال چون $\sum_{j=0}^{\infty} P(n_t = j | \phi_t) = 1$ چگالی شرطی بازده را می‌توان چنین نوشت:

$$P(R_t | \phi_{t-1}) = \sum_{j=0}^{\infty} f(R_t | n_t = j, \phi_{t-1}) P(n_t = j | \phi_{t-1}) \quad (17)$$

از طرفی، معادله نوسانات پویای بازده نشان می‌دهد توزیع بازده از دو توزیع مستقل ε_{1t} و ε_{2t} تبعیت می‌کند، بنابراین از استاندارد بودن Z_t و نرمال بودن π_{tk} نتیجه می‌شود که چگالی شرطی بازده سمت راست رابطه نرمال و به صورت زیر است:

$$f(R_t | n_t = j, \phi_{t-1}) = \frac{1}{\sqrt{2\pi(h_t + j\delta_t^2)}} * \exp\left(\frac{-(R_t - \mu - \varphi_1 R_{t-1} + \theta_t \lambda_t - \theta_{tj})^2}{2(h_t + j\delta_t^2)}\right) \quad (18)$$

با استفاده از این چگالی و روش MLE، پارامترهای مدل را بدست می‌آوریم. بنابراین واریانس شرطی بازده برابر است با:

$$\text{Var}(R_t | \phi_{t-1}) = \text{Var}(\varepsilon_{1,t} | \phi_{t-1}) + \text{Var}(\varepsilon_{2,t} | \phi_{t-1}) = h_t + (\theta_t^2 + \delta_t^2) \lambda_t \quad (19)$$

و به وسیله پارامترهای بدست آمده جهش بازده برآورد خواهد شد.

روش‌های پیش‌بینی

در گام دوم، پس از مشخص کردن جهش‌های شاخص سهام، از دو طیف کلی شامل یادگیری ماشین و یادگیری عمیق استفاده خواهد شد که هر بخش شامل مدل‌های مختلفی خواهد بود. در این بخش، روش‌های یادگیری ماشین و رویکردهای یادگیری عمیق مورد استفاده در پژوهش، شامل دسته‌بندی‌کننده‌های مختلف، روش کاهش ابعاد مورد استفاده و روش‌هایی که به منظور تصمیم‌گیری نهایی در مورد خروجی دسته‌بندی‌کننده‌ها استفاده شده‌اند، به طور خلاصه معرفی شده‌اند.

مدل جنگل تصادفی^۱ (RF)

روش جنگل تصادفی جزئی از روش‌های طبقه‌بندی تحت نظارت گروهی در حوزه داده‌کاوی که به بخش یادگیری ماشین افزوده شده است. جنگل تصادفی (RF)، پتانسیل بسیار زیادی برای تبدیل به

1. Random Forests (RF)

یک روش محبوب برای طبقه‌بندی‌های آینده دارد، زیرا کارایی آن قابل مقایسه با دیگر روش‌های گروهی است. به عنوان یک الگوریتم گروهی، رویکرد جنگل تصادفی چندین درخت تصمیم مختلف به عنوان طبقه‌بندی‌های پایه تولید می‌کند و بیشترین رأی را برای ترکیب با نتایج درختان اصلی اعمال می‌کند. جنگل تصادفی هم توانایی رگرسیون و هم توانایی کلاس‌بندی را با هم دارد. روش کار در یک جنگل تصادفی چنین است که داده‌های نمونه‌ای با عمل‌گذاری به تعداد n مجموعه نمونه، تقسیم می‌شود و از هر دسته، نمونه‌ای برای آموزش یک درخت استفاده می‌شود. تمام درخت‌ها عمق مشخصی دارند و در هر گره تقسیم یک ویژگی یا فیچر به تصادف از بین مجموعه ویژگی‌ها انتخاب می‌شود و تقسیم یا شاخه‌بندی بر اساس آن صورت می‌گیرد. به علت استفاده از چندین دسته نمونه این روش مشکل داده‌های پرت و داده‌های گم شده را ندارد.

رویکرد ماشین بردار پشتیبان (SVMs)^۱

ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت است که هم برای دسته‌بندی و هم رگرسیون قابل استفاده است. ماشین بردار پشتیبان در اصل یک دسته‌بندی‌کننده دو کلاسی است که کلاس‌ها را توسط یک مرز خطی از هم جدا می‌کند. در این روش، نزدیکترین نمونه‌ها به مرز تصمیم‌گیری را بردارهای پشتیبان می‌نامند. این بردارها معادله مرز تصمیم‌گیری را مشخص می‌کنند. این روش به دلیل استفاده از اصل کمینه‌سازی ریسک ساختاری که از طریق بیشینه کردن فاصله بین دو ابر صفحه گذرا از بردارهای پشتیبان هر دو کلاس اعمال می‌شود، برخلاف حالت کمینه‌سازی ریسک تجربی که سعی در کمینه کردن خطای آموزش را دارد عملکرد بهتری بر روی داده‌هایی که مدل با آنها ساخته نشده است، از خود نشان می‌دهد. به منظور سادگی در فهم، برای بیان تئوری ماشین بردار پشتیبان از ساده‌ترین حالت ممکن یعنی دسته‌بندی دو کلاسی در حالت جدایی‌پذیر به صورت خطی توضیح داده شده است. بر این اساس، اگر فرض کنیم که X_i متغیر ورودی در یک رگرسیون وجود دارد که دارای تعداد y_i متغیر متناظر پاسخ‌دهنده است، ماشین بردار پشتیبان را می‌توان به صورت رگرسیون خطی زیر نشان داد:

$$f(xw) = w^T x + b \quad (20)$$

1. Support Vector Machines (SVMs)

که در آن بردار نرمال ابرصفحه جداکننده است که هدف، حداقل سازی تابع w است. برای یافتن مرز تصمیم گیری بهینه از روش حاشیه بیشینه استفاده می شود. بنابراین مرز تصمیم گیری افزون بر اینکه بایستی تمام نمونه های هر دو کلاس را به درستی به دو دسته تقسیم کند، باید مرز تصمیم گیری (ابر صفحه) را پیدا کند و بیشترین فاصله از همه بردارهای پشتیبان را داشته باشد. بنابراین می توان یک مسأله بهینه سازی به صورت زیر را تعریف کرد:

$$\min \frac{1}{2} \|w\|^2 \quad (21)$$

$$\text{s. t } y_i (w^T x + b) \geq 1$$

برای حل این مسأله، بهینه سازی از روش ضرایب لاگرانژ استفاده می شود. بر اساس شرایط کان - تاکر می توان مقادیر بهینه w بر اساس ضرایب لاگرانژ را به صورت زیر برآورد کرد:

$$w = \sum \alpha_i x_i y_i \quad (22)$$

که در آن ضرایب لاگرانژ تابع بهینه سازی است. مقدار b نیز به صورت زیر قابل برآورد است:

$$w = \frac{1}{N_{sv}} \sum y_i - w x_i \quad (23)$$

که در آن N_{sv} تعداد بردارهای پشتیبان است. بر این اساس، تابع تصمیم گیری با رویکرد ماشین بردار پشتیبان به صورت زیر است:

$$f(x) = \text{sgn}(w^T x + b) \quad (24)$$

روش شبکه عصبی مصنوعی (ANN)^۱

شبکه های عصبی از دهه ۵۰ شناخته شده بودند، اما تنها در اواسط دهه ۸۰ بود که الگوریتم ها و روش های وابسته به شبکه های عصبی مصنوعی به درجه ای از پیشرفت رسیدند که در حل مسائل واقعی از آنها استفاده شد. شکل ساده شبکه های عصبی مصنوعی (ANN) یک لایه ورودی و یک لایه خروجی دارد. لایه ورودی شامل متغیرهای ورودی شامل n تعداد متغیر است. لایه خروجی نیز شامل متغیرهای خروجی زیادی است که هر ورودی x به یک خروجی


1. Artificial Neural Networks (ANN)

لا متصل است. در حقیقت شبکه عصبی مصنوعی، مجموعه‌ای از نرون‌های به هم متصل در لایه‌های مختلف هستند که اطلاعاتی را برای یکدیگر ارسال می‌کنند. نرون‌های مصنوعی واحدهای ساده پردازش اطلاعات هستند، بنابراین تعداد زیادی از این نرون‌ها یک شبکه عصبی را می‌سازند.

پروش شبکه عصبی بازگشتی استوار بر یادگیری عمیق

یک شبکه عصبی بازگشتی (ANN) یک کلاس از شبکه‌های عصبی مصنوعی است که در آن ارتباط بین گره یک گراف هدایت شده در طول سری زمانی را ایجاد می‌کند. همانطور که مشخص است، این رویکرد به صورت بازگشتی عمل می‌کند. یعنی عملیاتی برای تمامی سری تصادفی انجام می‌گیرد و خروجی آن وابسته به ورودی فعلی و عملیات‌های قبلی است. این مهم از طریق تکرار یک خروجی از شبکه در زمان t ورودی شبکه در زمان $t+1$ انجام می‌شود (یعنی خروجی از مرحله قبل با ورودی تازه در مرحله جدید ترکیب می‌شوند). بدین ترتیب، این رویکرد می‌تواند وقایع مختلف تکرار شونده و تأثیرگذار را شناسایی و در پیش‌بینی‌های بعدی مورد استفاده قرار دهد.

در این رویکرد همانطور که اشاره شد، بخش اصلی آن بازگشت است. بر این اساس، بر نرون‌های مخفی بازگشتی را خواهد داشت که به صورت زیر قابل بیان است:

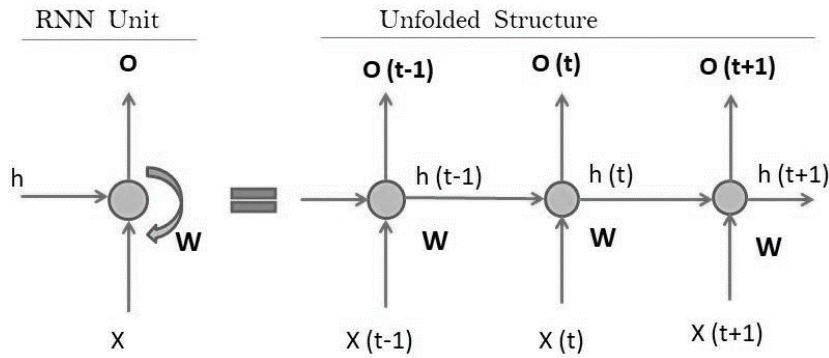


$$h(t) = f_H(W_{IH}x(t) + W_{HH}h(t-1)) \quad (26)$$

$$y(t) = f_O(W_{HO}h(t))$$

که در آن h نرون‌های مخفی، W وزن لایه‌های شبکه عصبی برای لایه ورودی به پنهان (IH)، پنهان به پنهان (HH) و پنهان به خروجی (HO) است. همچنین تابع f_H تابع فعال‌سازی

بخش پنهان و f_0 تابع فعال‌سازی بخش خروجی است. شمای کلی این ارتباط را می‌توان به صورت زیر مشاهده کرد:



داشتن یک حافظه بلندمدت‌تر دارای اثر تثبیت‌کننده است، چرا که حتی اگر شبکه نتواند از تاریخچه اخیر خود درک صحیحی پیدا کند، باز با این وجود می‌تواند با نگاه در گذشته، پیش‌بینی خود را کامل کند. یک راه حل که برای مدل‌های شرطی مطرح شده است، اضافه کردن نویز به پیش‌بینی‌های صورت گرفته توسط شبکه قبل از تغذیه آنها به گام زمانی بعدی است. این کار باعث تقویت شبکه در قبال ورودی‌های غیرمنتظره می‌شود. اما با این وجود، یک حافظه بهتر، راه حل به مراتب بهتر و تأثیرگذارتری است. حافظه طولانی کوتاه‌مدت (LSTM) یک معماری شبکه عصبی بازگشتی است که برای ذخیره‌سازی و دسترسی بهتر به اطلاعات نسبت به نسخه سنتی آن طراحی شده است.

بررسی ارزیابی مدل‌های مختلف

برای ارزیابی مدل‌های پیش‌بینی‌کننده، از مدل‌هایی که خطاهای مدل‌های پیش‌بینی‌کننده را اندازه‌گیری می‌کنند، استفاده خواهد شد. این مدل‌ها بر چند نوع عمده تقسیم‌بندی می‌شوند:

$$RMSE = \frac{1}{n} \sum_i \frac{(\hat{y}_i - y_i)^2}{\hat{y}_i \bar{y}_i} \quad \text{مربع میانگین خطای استاندارد نرمال شده}$$

$$SAMPE = \frac{1}{n} \sum_i (\hat{y}_i - \bar{y}_i)^2 \quad \text{میانگین انحراف معیار خطای پیش‌بینی}$$

$$MAPE = \sqrt{n^{-1} \sum_{t=1}^n (\sigma_{a,t}^y - \sigma_{a,t}^x)^2}$$

درصد خطای متوسط مطلق

$$MAE = n^{-1} \sum_{t=1}^n |\sigma_{a,t}^y - \sigma_{a,t}^x|$$

متوسط مطلق خطا

که در آنها n تعداد پیش‌بینی‌های انجام شده، $\sigma_{a,t}^y, \sigma_{a,t}^x$ به ترتیب مقدار اصلی پارامتر و پیش‌بینی پارامتر است که با استفاده از روش خارج از نمونه صورت می‌گیرد.

یافته‌های پژوهش

۱- جامعه آماری و متغیرهای پژوهش

متغیرهای مورد استفاده در این پژوهش شامل بازدهی شاخص کل بورس اوراق بهادار تهران، جهش‌های شاخص بورس اوراق بهادار تهران که به روش ARJI-GARCH استخراج شده و متغیرهای مؤثر بر بازار سهام به عنوان متغیر برون‌زا است.

متغیرهای برون‌زا بر اساس ادبیات تجربی پیرامون این موضوع و همچنین مطابق با مطالعات چاتزیس و همکاران (۲۰۱۸) و مقصود و همکاران (۲۰۲۱) انتخاب شده است، پس این انتخاب بر اساس طیف متغیرهای اقتصادی، شاخص بازار کالا، قیمت نفت، قیمت طلا، نرخ ارز و روند سایر بازارهای مالی و بین‌المللی است. فهرست متغیرهای مورد استفاده در این پژوهش در جدول (۱) خلاصه شده است. تمامی این داده‌ها به صورت روزانه با حذف روزهای تعطیل و روزهای کاری غیر همزمان بوده است. دوره مورد بررسی از مرداد ۱۳۹۲ تا بهمن ۱۳۹۹ شامل ۷۵۰ روز کاری مشترک با بازارهای جهانی بوده است.

جدول ۱. فهرست متغیرهای پژوهش

منبع	متغیر
مستخرج از مدل ARJI-GARCH	جهش‌های شاخص کل بورس تهران
سایت یاهو و فایننس	لگاریتم شاخص S&P500
سایت یاهو و فایننس	لگاریتم شاخص DAXI
سایت یاهو و فایننس	لگاریتم شاخص FCHI
سایت یاهو و فایننس	لگاریتم شاخص NIKKI

منبع	متغیر
سایت یاهو و فایننس	لگاریتم شاخص بورس امارات
سایت یاهو و فایننس	لگاریتم شاخص بورس چین
سایت یاهو و فایننس	لگاریتم شاخص ترکیه
سایت اوپک	لگاریتم قیمت نفت خام اوپک
بورس کالای شیکاگو	لگاریتم قیمت نفت خام برنت
آرشیو نرخ آزاد ارز داخلی	لگاریتم نرخ آزاد ارز (دلار آمریکا)
آرشیو نرخ آزاد ارز داخلی	لگاریتم نرخ آزاد ارز (یورو)
آرشیو نرخ آزاد ارز داخلی	لگاریتم نرخ آزاد ارز (پوند)
آرشیو نرخ آزاد ارز داخلی	لگاریتم نرخ آزاد ارز (یون)
آرشیو نرخ آزاد ارز داخلی	لگاریتم نرخ آزاد ارز (درهم امارات)
بورس کالای لندن	لگاریتم قیمت اونس طلا
آرشیو قیمت داخلی سکه طلا	لگاریتم قیمت سکه بهار آزادی

۲- برآورد جهش‌های بازار سهام

مقادیر برآورد شده مدل جهش برای بازدهی شاخص کل در طی زمان به روش یاد شده، به صورت متغیر در زمان برآورد شده و نتایج متغیر حاصل شده جهش به صورت نمودار (۱) استخراج شده است. بر اساس نتایج جدول (۲)، ضرایب برآورد شده به جز متغیر ω (عرض از مبدأ معادله واریانس شرطی) همگی در سطح ۵ و ۱۰ درصد خطا معنی دار هستند. این موضوع در بخش مدل جهش نشان دهنده این واقعیت است که مقادیر میانگین و واریانس مدل جهش معنی دار بوده و همچنین رفتار ARIJ نیز معنی دار است. معنی داری و علامت مثبت مقادیر λ_0 و ρ نشان می‌دهد که متغیر جهش دارای روندی است که رابطه خودرگرسیون مثبت و معنی داری را اختیار کرده است. این موضوع نشان می‌دهد که جهش‌ها در هر لحظه می‌توانند از جهش دوره قبل تأثیر بپذیرند.

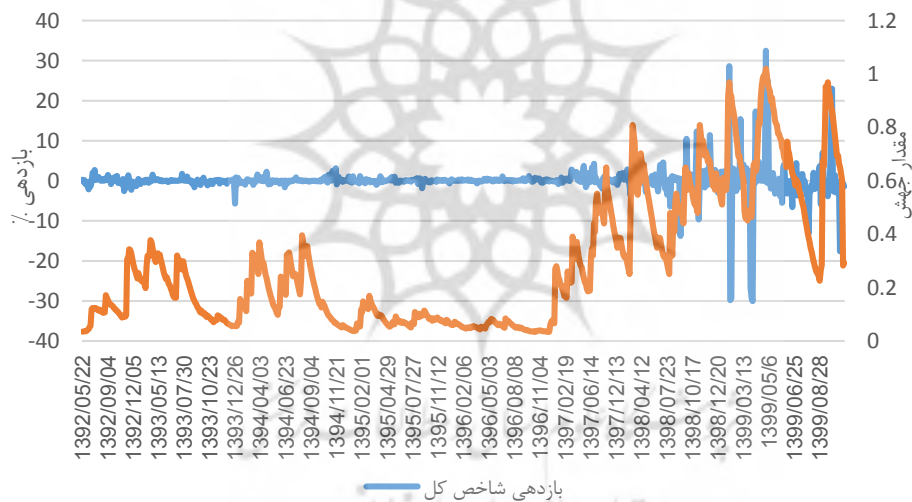
لازم به بیان است برآورد بخش میانگین (ARMA) با استفاده از رویکرد باکس جنکینز^۱ مرتبه بهینه ARMA(2,1) مشخص شده است. بخش واریانس و معادله جهش نیز مطابق با مقالات چان و ماهو^۲ (۲۰۰۲) و وانگ^۳ (۲۰۱۸) مرتبه GARCH(1,1) برآورد شده است.

1. Box-Jenkins
2. Chan, W. and J. Maheu (2002)
3. Wang, Y. (2018)

جدول ۲. برآورد جهش‌های بازار سهام

متغیر	ضریب	انحراف معیار	آماره t	مقدار احتمال
M	۰.۰۶۷۶	۰.۰۹۳۶	۰.۷۲۱۸	۰.۴۷۰۴
φ_1	-۰.۶۱۴۰ ^{***}	۰.۰۴۲۲	-۱۴.۵۴۴۸	۰.۰۰۰۰
φ_2	-۰.۳۳۹۸ ^{***}	۰.۰۲۷۵	-۱۲.۳۵۰۴	۰.۰۰۰۰
Ψ_1	۰.۵۹۶۲ ^{***}	۰.۰۴۱۹	۱۴.۲۳۰۸	۰.۰۰۰۰
ω	۰.۰۳۵۳	۰.۰۲۳۲	۱.۵۲۰۳	۰.۱۲۸۴
α	۰.۰۴۰۸ ^{**}	۰.۰۱۸۴	۲.۲۱۸۰	۰.۰۲۶۶
β	۰.۹۳۲۲ ^{***}	۰.۰۲۶۴	۳۵.۲۸۹۲	۰.۰۰۰۰
δ^2	۲.۲۱۲۴ ^{***}	۰.۴۲۰۷	۵.۲۵۸۲	۰.۰۰۰۰
θ	-۰.۵۰۵۲ ^{***}	۰.۰۴۱۲	-۱۲.۲۷۰۶	۰.۰۰۰۰
λ_0	۰.۰۳۷۵ ^{***}	۰.۰۰۳۶	۱۰.۴۹۶۳	۰.۰۰۰۰
ρ	۰.۹۸۵۹ ^{***}	۰.۰۱۳۸	۷۱.۲۲۸۲	۰.۰۰۰۰
γ	۰.۲۰۲۷ [*]	۰.۱۲۱۰	۱.۶۷۵۸	۰.۰۹۳۸

منبع: نتایج پژوهش

مقادیر ^{***}، ^{**}، ^{*} به ترتیب نشان‌دهنده معنی‌داری در سطوح ۱، ۵ و ۱۰ درصد است.

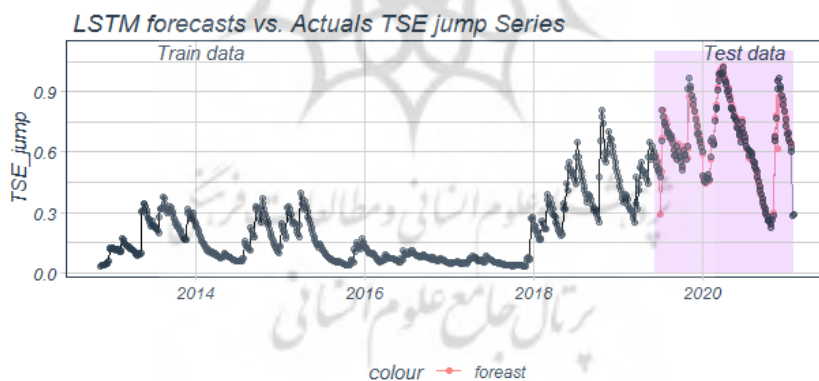
بازدهی شاخص کل

نمودار ۱. برآورد جهش‌های شاخص بورس تهران

در فرآیند پیش‌بینی سری‌های زمانی به روش یادگیری ماشین، به جای آنکه از مدل برای طولانی‌مدت برای پیش‌بینی دوره پیش‌رو استفاده شود، با پیش‌بینی دوره‌های گذشته محاسبه شده از مدل برآورد شده با داده‌های واقعی می‌توان عملکرد مدل را سنجید. بدین منظور، در این پژوهش از دو دوره استفاده شده است.

دوره اول دوره یادگیری (درون نمونه) و دوره آزمون (دوره خارج از نمونه) است. در این رهیافت لازم است یک دوره برازش^۱ در نظر گرفته شود که تخمین پارامترهای مدل را تعریف می کند و متغیر مستقل و تأثیر گذار بر شاخص جهش های بورس تهران تبیین می شود. این نمونه برازش^۲، در سراسر کل دوره داده ها به صورت یک دوره یادگیری طراحی می شود. با ثابت در نظر گرفتن دوره یادگیری، مدل های مختلف با استفاده از روش های الگوریتمی خود به الگوریتم مناسب جهت پیش بینی خواهند رسید و در نهایت اقدام به پیش بینی می کنند. برای پیش بینی های انجام شده در این پژوهش، از ۸۰ درصد کل داده ها به عنوان دوره یادگیری ماشین (درون نمونه) و مابقی داده ها به عنوان دوره آزمون (خارج از نمونه) استفاده شده است. همچنین پیش بینی برای دوره های پیش رو نیز به صورت یک، سه و شش روزه در نظر گرفته شده است تا بتوان این موضوع را به صورت کوتاه مدت و میان مدت نیز بررسی کرد.

در این پژوهش برای بررسی دقت پیش بینی های انجام شده، دوره آزمون (خارج از نمونه) با در نظر گرفتن ۲۰ درصد از کل داده ها به صورت یک، سه و شش روزه پیش بینی شده است. این موضوع افزون بر نشان دادن توانایی مدل های مختلف برای پیش بینی دوره های مختلف، توانایی هر مدل در این دوره ها را نیز خواهد سنجید. نتایج پیش بینی جهش های شاخص بورس اوراق بهادار که هدف اصلی این پژوهش است، برای پیش بینی یک روزه به روش شبکه عصبی بازگشتی LSTM در نمودار (۲) نمایش داده شده است. همانطور که مشخص است، روش شبکه عصبی بازگشتی به روش یادگیری عمیق، روند مناسبی داشته و پیش بینی به مقادیر واقعی بسیار نزدیک است.



نمودار ۲. پیش بینی دوره آزمون (خارج از نمونه) جهش های شاخص بورس روش LSTM

1. Estimation Period
2. Estimation Sample

۳- مقایسه مدل‌های پیش‌بینی‌کننده جهش‌های بورس اوراق بهادار


در جدول (۳) مقادیر ارزیابی توانایی پیش‌بینی‌ها برای دوره‌های ۱، ۳ و ۶ روزه به روش‌های بیان شده، یعنی مدل‌های متوسط مطلق خطا (MAE)، مدل RMSE و مدل درصد خطای متوسط مطلق (MAPE) ارزیابی شده است. نتایج نشان‌دهنده توانایی بهتر مدل شبکه عصبی بازگشتی استوار بر رویکرد LSTM است. این روش برای هر سه رویکرد یک، دو و سه روزه نتایج بهتری را حاصل کرده است. بدین ترتیب می‌توان بر اساس نتایج بیان کرد که هدف اصلی این پژوهش و پرسش اصلی در این بررسی به خوبی اثبات شده است. همچنین بیان داشت که روش شبکه عصبی بازگشتی استوار بر روش یادگیری عمیق، نتایج بهتری را به همراه داشته است.

جدول ۳. مقایسه مدل‌های پیش‌بینی‌کننده جهش‌های بورس اوراق بهادار

مدل	دوره پیش‌بینی	RSME	SAMPE	MADPE	MAPE	MAE
ANN	یک روزه	۰.۲۲۳	۶۲.۹۷۹	۱۶۱.۵۶۳	۱۸۲.۴۹۱	۰.۱۹۳
ANN	سه روزه	۰.۲۵۱	۶۸.۴۲۹	۱۸۸.۳۶۶	۲۰۵.۱۶۴	۰.۲۲۴
ANN	شش روزه	۰.۲۹۷	۷۶.۲۱۲	۲۰۸.۸۰۳	۲۲۷.۷۲۱	۰.۲۶۵
LSTM	یک روزه	۰.۰۶۳	۴۱.۷۵۲	۲۸.۲۹۶	۲۹.۱۴۷	۰.۰۴۸
LSTM	سه روزه	۰.۱۶۲	۸۲.۱۲۳	۶۸.۹۸۰	۸۳.۴۷۴	۰.۱۲۶
LSTM	شش روزه	۰.۲۶۸	۹۷.۷۶۸	۱۳۴.۷۳۴	۱۵۱.۵۰۱	۰.۲۱۹
RF	یک روزه	۰.۴۰۹	۱۰۹.۹۸۵	۲۴۶.۱۱۰	۲۷۷.۷۰۱	۰.۳۸۶
RF	سه روزه	۰.۴۱۰	۱۱۰.۰۱۷	۲۴۶.۸۶۴	۲۷۸.۵۵۰	۰.۳۸۶
RF	شش روزه	۰.۴۱۱	۱۱۰.۲۸۷	۲۴۷.۳۷۱	۲۷۹.۱۱۸	۰.۳۸۷
SVM	یک روزه	۰.۲۲۵	۶۳.۴۳۸	۱۶۲.۷۴۷	۱۸۵.۰۸۲	۰.۱۹۶
SVM	سه روزه	۰.۲۵۶	۶۹.۳۶۸	۱۹۰.۵۰۲	۲۰۵.۱۳۹	۰.۲۲۸
SVM	شش روزه	۰.۲۹۳	۷۵.۴۷۶	۱۹۸.۵۳۵	۲۲۳.۱۳۹	۰.۲۶۰

منبع: نتایج پژوهش

این نتایج در نمودار (۴) نمایش داده شده است. این نمودار نیز به خوبی نشان می‌دهد که نتایج به سود مدل شبکه بازگشتی عمیق به صورت یادگیری عمیق است.



نمودار ۴. مقایسه خطی مدل‌های مختلف پیش‌بینی جهش‌های شاخص بورس

نتیجه‌گیری

در این پژوهش، به بررسی توانایی مدل‌های مختلف پیش‌بینی جهش‌های شاخص کل بورس اوراق بهادار در ایران در دوره ۱۳۹۲ تا ۱۳۹۹ پرداخته شده است. برای رسیدن به این هدف، ابتدا به استخراج جهش‌های شاخص کل از رویکرد ARJI-GARCH پرداخته شد. سپس، با منظور کردن متغیرهای برون‌زا شامل بازارهای جهانی و داخلی به عنوان متغیرهای مؤثر بر این شاخص، به پیش‌بینی این جهش‌ها پرداخته شد. برای این هدف، از چهار رویکرد متفاوت در زمینه یادگیری ماشین شامل: جنگل تصادفی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی بازگشتی استوار بر یادگیری عمیق استفاده شد.

برای پیش‌بینی‌های انجام شده در این پژوهش، از ۸۰ درصد کل داده‌ها به عنوان دوره یادگیری ماشین (درون‌نمونه) و مابقی داده‌ها به عنوان دوره آزمون (خارج از نمونه) استفاده شده است. پیش‌بینی نیز برای افق‌های یک، سه و شش روزه در نظر گرفته شد. نتایج مقایسه داده‌های پیش‌بینی شده خارج از نمونه با مقادیر واقعی جهش‌های بازار سهام نشان می‌دهد که مدل استوار بر شبکه عصبی بازگشتی (LSTM) دارای کمترین معیارهای خطای مورد استفاده برای هر سه افق پیش‌بینی دوره خارج از نمونه شامل یک، سه و شش روزه بوده است. این نتایج با مقاله چاتزیس و همکاران (۲۰۱۸) هم‌سو است. بر این اساس، با توجه به توانایی مناسب مدل ARJI-GARCH برای برآورد جهش‌های بازار سهام پیشنهاد می‌شود از این مدل برای شناسایی

تلاطم شرطی و همچنین پیش‌بینی ریسک بازارهای مالی استفاده شد، به نحوی که برای تبیین سیستم هشدار بحران و تبیین نرخ پوشش بهینه نیز استفاده مؤثری برای مؤسسات مالی و فعالان بازار سرمایه داشته باشد. در نهایت با توجه به نتایج پیش‌بینی شاخص جهش و دقت مناسب شبکه عصبی بازگشتی در این مسیر، پیشنهاد می‌شود موضوع سیگنال‌دهی ایجاد شده و وجود راهبرد سودآور بین بازارهای موازی مورد توجه بازیگران بازارهای مالی و سرمایه‌گذاران قرار گیرد تا بتوانند با دانش از تغییرات بین بازارها و پیش‌بینی آنها به کنترل ریسک و بازدهی مالی بپردازند. برای مطالعات آتی نیز پیشنهاد می‌شود مدل‌های یاد شده در این پژوهش در پیش‌بینی بازدهی و تلاطم شاخص کل سهام مورد استفاده قرار گیرد. همچنین پیشنهاد می‌شود از متغیرهای بازار داخلی همچون قیمت سایر دارایی‌های مالی به عنوان متغیرهای برون‌زای مؤثر بر پیش‌بینی بازار سهام استفاده شود.



منابع

- باجلان، سعید؛ فلاحپور، سعید؛ دانا، ناهید. (۱۳۹۵). "پیش‌بینی روند تغییرات قیمت سهام با استفاده از ماشین بردار پشتیبان وزن‌دهی شده و انتخاب ویژگی هیبرید به منظور ارائه استراتژی معاملاتی بهینه"، *راهبرد مدیریت مالی*، ۴(۳)، ۱۲۱-۱۴۸.
- دهقانی، مریم؛ قاسم‌زاده، محمد؛ انصاری سامانی، حبیب. (۱۳۹۸). "الگوریتم‌های یادگیری ماشین برای سری‌های زمانی در بازارهای مالی"، *مجله علمی رایانش نرم و فناوری اطلاعات*، ۳(۳)، ۶۷-۶۰.
- راعی، رضا؛ نیک‌عهد، 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(۴)، ۲۳-۱.
- فقیهی‌نژاد، محمدتقی؛ مینایی، بهروز. (۱۳۹۷). "پیش‌بینی رفتار بازار سهام بر اساس شبکه‌های عصبی مصنوعی با رویکرد یادگیری جمعی هوشمند"، *فصلنامه مدیریت صنعتی*، ۱۰(۲)، ۳۳۴-۳۱۵.
- فلاح‌پور، سعید؛ علی‌پور ریکنده، جواد. (۱۳۹۳). "پیش‌بینی شاخص سهام با استفاده از شبکه‌های عصبی موجکی در بورس اوراق بهادار تهران"، *راهبرد مدیریت مالی*، ۲(۴)، ۳۱-۱۵.

References

- Adebiyi, A. A., Adewumi, A.O., & Ayo, C. K. (2014). "Comparison of ARIMA and artificial neural networks models for stock price prediction". *Journal of Applied Mathematics*, 1-7.
- Bajlan, Saeed; Falahpour, Saeed; Dana, Nahid. (2015). "Forecasting stock price trends using weighted support vector machine and hybrid feature selection to provide optimal trading strategy", *Financial Management Strategy*, 4(3), 121-148. (In Persian).
- 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., Michniukab, K. (2015) "Stock market trading rule based on pattern recognition and technical analysis: Forecasting the DJIA index with intraday data", *Expert Systems with Applications* 42: 5963-5975.
- Chaim, Pedro, and Márcio P. Laurini. (2018). "Volatility and return jumps in bitcoin". *Economics Letters* 173: 158-63.
- Chan, W. and J. Maheu (2002), "Conditional Jump Dynamics in Stock Market Returns", *Journal of Business and Economic Statistics*, vol 20, no. 3, 377-389.
- Chatzis, S. P., Siakoulis, V., Petropoulos, A., Stavroulakis, E., & Vlachogiannakis, N. (2018). "Forecasting stock market crisis events using deep and statistical machine learning techniques". *Expert Systems with Applications*, 112, 353-371.
- Chiang, W.-C., Enke, D., Wu, T., Wang, R. (2016) "An adaptive stock index trading decision support system", *Expert Systems with Applications* 59: 195- 207.
- Christiansen, C. and Ranaldo, A. (2009) "Extreme coexceedances in new EU member states' stock markets." *Journal of banking & finance* 33(6): 1048-1057.
- Dehghani, Maryam; Ghasemzadeh, Mohammad; Ansari Samani, Habib. (2018). "Machine Learning Algorithms for Time Series in Financial Markets", *Scientific Journal of Soft Computing and Information Technology*, 3(3), 67-60. (In Persian).

- Duan, Y., Goodell, J. W., Li, H., & Li, X. (2021). "Assessing machine learning for forecasting economic risk", Evidence from an expanded Chinese financial information set. *Finance Research Letters*.
- Falahpour, Saeed; Alipour Rikande, Javad. (2013). "Prediction of stock index using wavelet neural networks in Tehran Stock Exchange", *Financial Management Strategy*, 2(4), 15-31. (In Persian)
- Faqihi Nejad, Mohammad Taghi; Minaei, Behrouz. (2017). "Prediction of Stock Market Behavior Based on Artificial Neural Networks with Intelligent Collective Learning Approach", *Industrial Management Quarterly*, 10(2), 334-315. (In Persian)
- Kim, Y., H., Chang, W., H. (2018) "Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models", *Expert Systems with Applications* 103: 25-37.
- Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aadil, F., Selim, M. M., ... Muhammad, K. (2021). "A local and global event sentiment based efficient stock exchange forecasting using deep learning". *International Journal of Information Management*, 50, 432-451.
- Nevasalmi, L. (2020). "Forecasting multinomial stock returns using machine learning methods". *The Journal of Finance and Data Science*, 6, 86-106.
- Oztekin, A., Kizilaslan, R., Freund, S. and Iseri, A. (2016) "A data analytic approach to forecasting daily stock returns in an emerging market" *European Journal of Operational Research*, 253(3): 697-710.
- Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). "Predicting stock market index using fusion of machine learning techniques". *Expert Systems with Applications*, 42, 4, 2162-2172.
- Rai, Reza; Nikahed, Ali; Habibi, Mustafa. (2015). "Prediction of Tehran Stock Exchange index by combining methods of principal component analysis, support vector regression and cumulative movement of particles", *Financial Management Strategy*, 4(4), 1-23. (In Persian).
- Wang, Y. (2018). "The Jump Dynamics of the Industry-Specific Nominal Effective Exchange Rate of RMB and the Impact of Major International Currencies on It—An Empirical Study Based on the ARJI Model". *Journal of Financial Risk Management*, 7, 1, 65-98.
- Xiao, Y., Xiao, J., Lu, F., & Wang, Sh. (2013). "Ensemble ANNs-PSO-GA Approach for Day-ahead Stock E-exchange Prices Forecasting". *International Journal of Computational Intelligence Systems*, 6(1), 96-114.
- Zhong, X., Enke, D. (2017) "Forecasting daily stock market return using dimensionality reduction." *Expert Systems with Applications* 67: 126-139.

COPYRIGHTS



© © 2022 by the authors. Licensee Securities and Exchange Organization, Tehran, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY NC 4.0) (<https://creativecommons.org/licenses/by-nc/4.0/>).