

## **A study on the characteristics of TSE index return data and introducing a regime switching prediction method based on neural networks**

Research Paper

**Amin Aminimehr\* , Saeed Bajalan\*\*, Hanieh Hekmat\*\*\***

### **Abstract**

This research has aimed at studying the characteristics and data generation process of TSE index daily return. Applying various tests showed that return data of TSE index follows a chaotic and clustered behavior. Furthermore, beside the condition of efficiency in this market, a novel prediction method is developed. The method introduced in this paper is formed from two consecutive neural networks; a mixture density neural network and a Long short-term memory neural network. It is worthy of note that the proposed method is associated with the inferred statistical structure from the data. The entire model is compiled in order to predict TSE index considering various number of regimes using daily data December 2008 up to April 2021. Results from various statistical tests rejected the weak form of efficiency and manifested a chaotic behavior in TSE index return. Furthermore, the developed prediction method gained higher accuracy than the same method without considering regimes. Results from Diebold-Mariano test significantly implied the differences of the accuracy between the models with regimes and without regimes. Finally, a back test by considering transaction cost showed that the strategy based on the predicted direction of the model with regimes gains higher return than market benchmark and the model without regimes.

**Keywords: Return prediction; Deep neural network; Adaptive Market Hypothesis; Efficient Market Hypothesis; Regime switching model.**

---

Received: 2021.May.26, Accepted: 2021.October.28.

\*Masters student in Financial Management, Ershad Damavand Higher Education Institute, Tehran, Iran (Corresponding Author).

E-mail: aminaminimehr@outlook.com

\*\* Assistant prof, Department of Financial Management and Insurance, University of Tehran, Tehran, Iran.

\*\*\*Assistant prof, Department of Accounting, Al Zahra University, Tehran, Iran.

## مطالعه‌ای بر رفتار داده‌های بازده شاخص بورس تهران و ارائه روش پیش‌بینی تغییر رژیم مبتنی بر شبکه‌های عصبی عمیق

امین امینی‌مهر\*، سعید باجلان\*\*، هانیه حکمت\*\*\*

مقاله پژوهشی

### چکیده

در این پژوهش با نگاهی آماری بر داده‌های بورس تهران اقدام به شناسایی رفتار و فرآیند تولید داده‌های بازده روزانه شاخص بورس تهران شده و پس از انجام آزمون‌های متعدد، با شناسایی رفتار آماری این داده‌ها و اظهار نظر راجع به کارایی این بازار، اقدام به توسعه مدلی نوین برای پیش‌بینی آن شده است. لازم به ذکر است که ساختار مدل ارائه شده مطابق با رفتار آماری این داده‌ها تدوین شده است. مدل ارائه شده متشکل از دو شبکه عصبی مصنوعی احتمال ترکیبی و حافظه کوتاه‌مدت و بلندمدت ماندگار می‌باشد که با در نظر گرفتن تعداد رژیم‌های رفتاری متفاوت، حرکات روزانه بازده شاخص بورس تهران را در بازه زمانی آذر ۱۳۸۷ تا فروردین ۱۴۰۰ توضیح می‌دهد. آزمون‌های متفاوت کارایی ضعیف بازار را رد کرده و ذات آشوبی را در رفتار بازده شاخص کل بورس تهران نشان می‌دهد. مدل ارائه شده در این پژوهش توانسته است دقت بهتری نسبت به مدل بدون در نظر گرفتن رژیم کسب بنماید. آزمون دیابولد ماریانو معنی‌دار بودن این تفاوت دقت مدل‌ها را تأیید کرده و آزمون معکوس با در نظر گرفتن هزینه معاملاتی نشان داده است که استراتژی این مدل با در نظر گرفتن چند رژیم، بازده بالاتری نسبت به مدل بدون رژیم و شاخص بازار کسب می‌کند.

**کلیدواژه‌ها:** پیش‌بینی بازده؛ شبکه عصبی عمیق؛ فرضیه بازار تطبیق‌پذیر؛ فرضیه بازار کارا؛ مدل تغییر رژیم.

تاریخ دریافت مقاله: ۱۴۰۰/۰۳/۱۵، تاریخ پذیرش مقاله: ۱۴۰۰/۰۸/۰۶.

\* دانشجوی کارشناسی ارشد مدیریت مالی، موسسه آموزش عالی ارشاد دماوند، تهران، ایران (نویسنده مسئول).

E-mail: aminaminimehr@outlook.com

\*\* استادیار، گروه مالی و بیمه، دانشگاه تهران، تهران، ایران.

\*\*\* استادیار، گروه حسابداری، دانشگاه الزهراء، تهران، ایران.

## ۱. مقدمه

امروزه در بسیاری از مجامع تخصصی مالی (دانشگاه‌ها، صندوق‌های سرمایه‌گذاری، شرکت‌های سبد گردانی، شرکت‌های مشاور سرمایه) به‌ویژه در فضای تجاری تفاوت دیدگاه‌های عمیقی در خصوص کارایی انواع تحلیل‌های مالی (تکنیکال و بنیادی) وجود دارد. یکی از مهم‌ترین اقدامات جهت شناخت بازار و انتخاب نوع تحلیل مناسب برای پیش‌بینی، آنالیز دقیق رفتار داده‌های بازار و شناخت رفتار آماری آن می‌باشد. در ادبیات اقتصادسنجی و مدل‌های پیش‌بینی سری‌های تالطم همواره چالش‌های فراوانی وجود داشته است و به‌عنوان یکی از مهم‌ترین آن‌ها، می‌توان بر رفتار خوشه‌ای سری بازده اشاره کرد. در این حوزه، پیشرفت در حال توسعه‌ی مدل‌سازی مالی، همواره پژوهشگران بیشتری را تشویق به پژوهش در حوزه‌ی کارایی بازار نموده است. از جمله این پژوهش‌ها در بازار بورس تهران می‌توان بر پژوهش حکمت و دیگران به کمک مدل پویا و ایستا آن‌ها [۲۱] و همچنین به پژوهش‌های تهرانی و دیگران به کمک مدل تغییر رژیم مارکوف آن‌ها اشاره نمود [۴۲].

مسئله پیش‌بینی بازارهای مالی همواره امری پیچیده بوده است. دلیل این موضوع را می‌توان از یک سو عدم شناخت کافی بر رفتار آماری این داده‌ها و از سوی دیگر بر عدم تطابق مدل‌های تدوین شده با رفتار داده‌های مورد مطالعه دانست. همچنین بسیاری از پژوهش‌های ارائه دهنده مدل‌های پیش‌بینی بر روی بازارهای مالی شناختی راجع به سطح کارایی آن بازارها نداشته‌اند، بنا بر این ارائه مدل پیش‌بینی از سوی آن‌ها لزوماً به معنی کسب سود مازاد نبوده است.

این پژوهش به دنبال دو هدف اساسی است. اول این که آیا طبق آزمون‌های آماری موجود، بازار بورس تهران در سطح ضعیف کارا می‌باشد یا خیر؟ بنابراین با استفاده از آزمون‌های متفاوت آماری، رفتار داده‌های شاخص کل بورس تهران مطالعه شده و بر اساس نظرات پژوهشگران مالی اظهار نظری راجع به نوع کارایی بازار بورس تهران خواهد شد. در ادامه با استفاده از یک روش نوین و ایجاد یک مدل انتها به انتها<sup>۱</sup> تلاش به ارائه روش جدیدی برای پیش‌بینی شاخص کل بورس تهران شده است. روش استفاده شده در این پژوهش از تلفیق یک شبکه عصبی احتمالی ترکیبی<sup>۲</sup> و یک شبکه عصبی عمیق حافظه کوتاه و بلندمدت ماندگار<sup>۳</sup> حاصل شده است. این تلفیق اولاً متناسب با ذات رفتار داده‌های شاخص بورس تهران بوده و همچنین منجر به ایجاد یک روش نوین در پیش‌بینی بازده می‌شود.

بنابراین، هدف دوم این پژوهش، بررسی و مقایسه دقت پیش‌بینی مدل با لحاظ رژیم رفتاری بازده شاخص بورس تهران با مدل پیش‌بینی بدون بازنمایی‌های رژیم می‌باشد. در این پژوهش ابتدا بر پیشینه مربوط به تاریخچه‌ی پیش‌بینی پذیر بودن بازارهای مالی و مدل‌های ارائه شده

<sup>۱</sup> End to End

<sup>۲</sup> Mixture Density Neural Network

<sup>۳</sup> Long short-term memory

در این حوزه پرداخته شده، سپس مدل‌های استفاده شده در این پژوهش همراه با فرمول‌ها و معماری‌های بکار رفته توضیح داده شده است. در ادامه، روش انجام این پژوهش توضیح داده شده و سپس به بررسی و مقایسه نتایج به دست آمده از مدل‌های پیش‌بینی متفاوت پرداخته شده است. و در پایان جمع‌بندی و اظهار نظر راجع به نتایج به دست آمده بیان شده است.

## ۲. مبانی نظری و پیشینه پژوهش

در سال ۱۹۶۵ میلادی فاما برای اولین بار با طرح فرضیه بازار کارا<sup>۱</sup>، بیان کرد در صورتی که در یک بازار مالی فروزی که بیان می‌کند برقرار باشند، سرمایه‌گذاران نمی‌توانند با تحلیل‌های خود از آن بازار سود مازاد کسب کنند. در واقع فاما معتقد بود که بازارهای کارا با سرعت بسیار بالایی اطلاعات را در قیمت سهم، دارایی، شاخص، و ... منعکس می‌کند و فرصتی برای سرمایه‌گذاران نمی‌گذارند تا از اطلاعات شان استفاده کنند. در واقع فاما معتقد بود: داده‌های قیمت در بازارهای کارا از رفتار گام تصادفی<sup>۲</sup> پیروی می‌کند. از گفته‌های فاما می‌توان این نتیجه را حاصل کرد که رفتار بازده سهام باید احتمالاً شبیه به رفتار نوفه سفید<sup>۳</sup> باشد [۱۵].

از سال ۱۹۶۵ میلادی به بعد اگر چه پژوهشگرانی در صدد ارائه نوعی رفتار دیگر برای داده‌های بازارهای بورس بودند، اما روند فکری فاما بیش از دیگران مورد توجه قرار گرفت. از جمله کسانی که نوعی تعریف دیگر برای داده‌های قیمت در بورس ارائه دادند می‌توان به ساموئلسون اشاره کرد که به جای رفتار گام تصادفی، به رفتار مارتینگلی<sup>۴</sup> برای قیمت سهام قائل بود. اگر چه که ساموئلسون بیان دیگری برای رفتار داده‌های قیمت ارائه کرد اما با فاما در مورد پیش‌بینی ناپذیر بودن قیمت در بازارهای کارا اتفاق نظر داشت [۳۸].

آنچه فاما در سال ۱۹۶۵ بیان کرد فروزی است که در صورت برقرار بودن آن‌ها بازار غیر قابل پیش‌بینی می‌شود. اما سوال اصلی این است که آیا واقعا آن فروض در هر بازاری برقرار است؟ این سوال باعث شد که پژوهشگرانی که علاقه مند به پیش‌بینی بازارهای مالی هستند اقدام به بررسی‌هایی در مورد برقراری آن فروض و گام تصادفی بودن رفتار داده‌های بازارهای متفاوت بنمایند [۱۲، ۳۳، ۴۲، ۲۱].

در سال‌های بعد از صحبت‌های اولیه فاما، آزمون‌ها و پژوهش‌هایی که برای بررسی کارایی بازار طراحی شدند بیشتر مبتنی بر روش‌های خطی بودند [۱۱، ۳۷]. اما در سال ۱۹۸۵ میلادی، لو با طراحی آزمونی مبتنی بر تلاطم، کارایی بسیاری از بازارهایی را که با استفاده از پژوهش‌های پیشین رد نشده بود، رد کرد. علاوه بر این، لو توانست حافظه بلندمدت در داده‌های بازار را مشاهده

<sup>۱</sup> Efficient Market Hypothesis

<sup>۲</sup> Random walk

<sup>۳</sup> White noise

<sup>۴</sup> Martingale

کند که این نیز نشان از امکان پیش‌بینی بازار با استفاده از داده‌های تاریخی است [۱۳، ۲۷]. توسعه‌ای که لو انجام داد باعث شد بسیاری از پژوهش‌هایی که از زمان فاما برای پیش‌بینی بازار بورس متوقف و ناامید شده بود از سر گرفته شود و پژوهشگران در پی یافتن راه‌هایی برای استخراج دانش میان داده‌های قیمت باشند. پس از لو گروهی از پژوهشگران با نام‌های براک دچرت شاینکمن و لبرون آزمونی را طراحی کردند تحت عنوان آزمون بررسی استقلال سری‌های زمانی (BDS) [۱۰]. این آزمون در حال حاضر جزء قوی‌ترین و سخت‌گیرانه‌ترین آزمون‌های آماری است و برای بررسی استقلال سری‌ها زمانی استفاده می‌شود. در واقع این آزمون بررسی می‌کند که آیا یک سری داده که منطبق سری زمانی در آن‌ها حاکم است خواص مستقل و یکسان<sup>۱</sup> بودن را دارند یا خیر. در واقع می‌توان اظهار کرد که اگر یک سری زمانی مستقل و یکسان باشد دانش قابل استخراجی در آن وجود ندارد و در واقع رفتار داده‌ها کاملاً تصادفی می‌باشد. در مقابل اما، رد شدن فرض صفر آزمون استقلال سری زمانی آن‌ها به معنای لزوم پیش‌بینی پذیری داده‌ها نیست اما چنین شرطی لازم است. امروزه از آزمون استقلال سری زمانی (BDS) برای بررسی رفتار خطی و غیر خطی داده‌های سری زمانی نیز استفاده می‌شود.

علاوه بر آنچه تا به حال ذکر شد، لو در سال ۲۰۰۴ میلادی مفهومی را معرفی کرد که به نوعی اصلاحی بر فرضیه بازار کارا فاما بود. مفهومی که لو در سال ۲۰۰۴ معرفی کرد اولین بار توسط شیلر در سال ۱۹۸۱ هنگام منتشر شدن یک خبر جدید در بازار مشاهده شده بود. شیلر اتفاقی را شاهد بود که با ادبیات تا آن موقع علم مالی قابل توضیح نبود. رفتاری که شیلر مشاهده کرده بود نوسانات شدید مقطعی بازده قیمت بعد از اعلام یک خبر جدید در بازار بود [۳۷]. لو در واقع در سال ۲۰۰۴ با مفهوم فرضیه بازار تطبیق پذیر<sup>۲</sup> برای این اتفاق توضیحی فراهم کرد. او برای توضیح این موضوع اذعان کرد که همه ی سرمایه‌گذاران لزوماً به صورت عقلایی<sup>۳</sup> سرمایه‌گذاری نمی‌کنند و دلیل آن هم این است که در اثر فشارهای احساسی و روانی ممکن است در شرایط جدید دچار اشتباه شوند. لو اما، اینطور ادامه داد که سرمایه‌گذاران با گذشت زمان پس از شرایط ناگهانی جدید در بازار به تدریج با شرایط جدید همگام شده و اصطلاحاً با شرایط جدید تطبیق پیدا می‌کنند [۲۸]. در واقع بازار پس از هر باری که خبر جدید در آن منتشر می‌شود به حالت غیر کارا طبق تعریف فاما در آمده و بعد دوباره به سمت کارا شدن حرکت می‌کند. از این روست که شاخه مالی رفتاری در ادبیات مالی، امروزه بسیار پر رونق و مورد توجه واقع شده است [۲].

بنابر آنچه که گفته شد در ادبیات مالی و اقتصادسنجی همواره فاصله‌ای میان رد شدن فرض نوفه سفید بودن سری داده‌های بازده در بازار بورس و امکان پیش‌بینی بازار با استفاده از ابزارهای توسعه یافته فعلی وجود دارد. در واقع آزمون آماری که براک، دچرت، شاینکمن و لبرون طراحی

<sup>۱</sup> Independent and Identically Distributed

<sup>۲</sup> Adaptive Market Hypothesis

<sup>۳</sup> Rational

کردند لزوماً به وجود ضریب یا ضرائب پیش‌بینی اذعان نمی‌کند بلکه فرض استقلال و یکسان بودن سری زمانی را در داده‌های سری بازده بررسی می‌کند. در نتیجه شاخه پیش‌بینی را در ادبیات مالی، اقتصادسنجی و در دید کلی تر داده کاوی توسعه می‌دهد. حال ادامه راه بر عهده پژوهشگران رشته‌های گوناگون از جمله علم داده<sup>۱</sup> است که به توسعه در حوزه استخراج روابط، استخراج دانش و پیش‌بینی بپردازند.

در یک جمع‌بندی از ایده بازار کارایی فاما، مشاهدات شیلر، بیانات و تعدیلات لو بر فرضیه بازار کارا، آزمون براک، دچرت شاینکمن و لبرون می‌توان این نتیجه را گرفت که بازارهای متشکل، از یک سیستم پویا تشکیل شده‌اند که دائماً در حال اصلاح خود و حرکت به سمت کارا شدن می‌باشند [۳۰]. در واقع این بازارها نسبت به تغییرات بسیار حساس بوده و سریعاً واکنش نشان می‌دهند. به بیانی دیگر می‌توان این طور گفت که بازارها نسبت به یک خبر جدید، نیروی جدید و حتی ابزار پیش‌بینی جدید واکنش نشان می‌دهند و به حالت غیر کارا در می‌آیند اما مکانیسم پویای بازار به مرور بازار را به سمت همگام شدن با وضعیت جدید می‌برد و بازار مجدد به وضعیت ثابت و کارا بر می‌گردد. نکته بسیار با اهمیت این است که بازه زمانی این فرایند تکرار شونده چرخه از بین رفتن کارایی بازار و کارا شدن مجدد آن با پیشرفت علم و سرعت انجام معاملات و ورود ربات‌های هوشمند معامله گر می‌تواند دائماً کوتاه تر شود. با توجه به جمع بندی ذکر شده، شاخه پیش‌بینی در ادبیات مالی همچنان گشوده باقی مانده است و پژوهشگران دائماً در حال توسعه و ارائه روش‌های جدید برای پیش‌بینی هستند [۳۲، ۳۶، ۲۰].

در راستای مدل‌سازی رفتار داده‌های سری زمانی بازارهای مالی، مدل‌های مختلفی توسعه یافته است. از جمله مهم‌ترین این مدل‌ها که برای توضیح تلاطم، توسعه یافته است می‌توان به مدل ARCH<sup>۲</sup> از [۱۴] که موجب دریافت جایزه نوبل برای او شد و شکل تعمیم یافته آن یعنی GARCH<sup>۳</sup> از [۹] اشاره کرد. در ادامه مدل‌های دیگری تحت عنوان خانواده GARCH توسعه یافتند که هر کدامشان ایراد خاصی از مدل GARCH اولیه مثل عدم تقارن توزیع متغیر و حافظه کوتاه‌مدت مدل را رفع می‌کردند. از طرفی محقق دیگری به نام همیلتون رویکرد متفاوتی را برای مدل‌سازی نسبت به مدل‌های خانواده ARCH و GARCH اتخاذ کرد. تفاوت اساسی فروض مدل همیلتون با فروض مدل اینگِل و کسانی که مدل او را توسعه داده بودند، در دیدگاه آن‌ها نسبت به تابع مولد توزیع داده‌های مورد مطالعه بود. در واقع همیلتون برای فرآیند تولید داده‌های اقتصادی دارای خواص خوشه‌ای<sup>۴</sup>، به بیش از یک توزیع آماری قائل بود. او معتقد بود که داده‌های آماری

<sup>۱</sup> Data Science

<sup>۲</sup> Auto Regressive Conditional Heteroskedasticity

<sup>۳</sup> Generalized Auto Regressive Conditional Heteroskedasticity

<sup>۴</sup> Data Generation process

<sup>۵</sup> Clustered

بعضی متغیرها ممکن است از دو یا چند تابع مولد با پارامترهای متفاوت تولید شوند [۱۸]. این دیدگاه نسبت به فرایند تولید داده و اساساً مدل‌های دارای چند تابع مولد، قبل از او نیز وجود داشت [۳۴]، اما نوآوری مدل همیلتون در نوع انتقال از یک تابع مولد به تابع مولد دیگر بود. همیلتون معتقد بود که متغیر پنهانی<sup>۱</sup> وجود دارد که از منطق مارکوف<sup>۲</sup> مرتبه اول پیروی می‌کند و باعث انتقال از یک تابع مولد به تابع مولد دیگر می‌شود. از آنجایی که این توابع مولد را متناظر با چرخه‌های اقتصادی می‌دانند آن‌ها را رژیم نامیده و مدل همیلتون یک مدل تغییر رژیم مارکوف<sup>۳</sup> نام گرفت. تا به اینجای مدل‌هایی که معرفی شده‌اند از دسته مدل‌های کلاسیک آماری یا همان مدل‌های محاسبات سخت<sup>۴</sup> بودند. این دسته از مدل‌ها محدودیت‌هایی دارند از جمله این محدودیت‌ها از دست دادن درجه آزادی، پیشفرض‌های آماری محدود کننده، مشکلات همبستگی داخلی متغیرهای مستقل هستند.

از سوی دیگر مدل‌هایی معرفی شده‌اند که در دسته مدل‌های محاسبات نرم<sup>۵</sup> قرار می‌گیرند. یکی از مهم‌ترین ویژگی‌های مثبت این دسته از مدل‌ها، نداشتن بسیاری از فروض محدود کننده مدل‌های کلاسیک می‌باشد [۱۹]. مدل‌های یادگیری ماشین<sup>۶</sup> را می‌توان از دسته مدل‌های محاسبات نرم نامگذاری کرد. شبکه‌های عصبی که از دسته مدل‌های یادگیری ماشین می‌باشند در حال حاضر از داغ‌ترین روش‌های محاسبات عددی و تخمین هستند. که هر ساله توجه پژوهشگران بیشتری را به خود جلب می‌کنند. از سایر نکات مثبت این روش‌ها می‌توان بر امکان واکاوی اثر همبستگی متغیرهای مستقل، امکان استفاده از تعداد متغیرهای مستقل زیاد بدون از دست دادن درجه آزادی و انعطاف پذیری بالاتر در سنجش روابط غیر خطی بسیار پیچیده اشاره کرد.

همزمان با ایده همیلتون، پژوهشگری به نام بیشاپ [۸]، در حوزه شبکه‌های عصبی، در حال مدل‌سازی‌هایی بر روی داده‌های مربوط به بازوان رباط بود که با مسئله‌ای مشابه مسئله همیلتون مواجه شد. در واقع بیشاپ در پی حل مسئله‌ای بود که متغیر وابسته آن دارای بیش از یک توزیع بوده و رخ دادن یک متغیر مستقل می‌توانست منجر به بیش از یک جواب شود. به بیانی دیگر متغیر وابسته مسئله‌ای که بیشاپ با آن مواجه بود تابع متغیر مستقل و پارامترهای توزیعی بود که متغیر وابسته در آن قرار می‌گرفت. در تخمین‌های معمول که مسئله را با فرض تولید داده‌ها از یک تابع مولد حل می‌کنند، میانگین جواب داده‌های آموزش دیده در هنگام آزمون و پیش‌بینی به عنوان پاسخ، در خروجی ارائه می‌شود که لزوماً جواب صحیحی نیستند.

<sup>۱</sup> Latent Variable

<sup>۲</sup> Markov

<sup>۳</sup> Markov regime switching

<sup>۴</sup> Hard computing

<sup>۵</sup> Soft computing

<sup>۶</sup> Machine learning

پیشاپ برای حل این مسئله الگوریتمی را طراحی کرد که در آن با اختصاص جواب‌های متفاوت به توزیع‌های مختلف، سعی بر دسته‌بندی توزیع‌های مولد جواب داشت. این شبکه عصبی امروزه به نام شبکه عصبی احتمال ترکیبی شناخته شده است. پیشاپ از شبکه عصبی مذکور در حل مسائل مالی نیز استفاده نمود. وی در مقاله‌ای در سال ۱۹۹۴ به مبحث تخمین در مسائل معکوس پرداخت. در این نوع مسائل معمولاً توزیع متغیر وابسته رفتار خوشه‌ای دارد و از بیش از یک توزیع تولید شده است.

امروزه شبکه‌های عصبی بازگشتی<sup>۱</sup> ای توسعه یافته‌اند که در بررسی داده‌های سری زمانی بسیار قدرتمند تر از شبکه‌های عصبی کلاسیک پرسپترون چند لایه<sup>۲</sup> قبل عمل می‌کنند. از جمله مهم‌ترین این شبکه‌های عصبی بازگشتی می‌توان بر شبکه‌های عصبی حافظه کوتاه و بلندمدت ماندگار اشاره کرد. این شبکه‌های عصبی امروزه در امر پیش‌بینی بازارهای مالی نیز مورد استفاده قرار گرفته‌اند.

در سال‌های اخیر در مباحث مرتبط با هوش مصنوعی<sup>۳</sup> پیشرفت گسترده‌ای برای حل بسیاری از مسائل مالی انجام شده است [۳۱]. در ادامه به خلاصه‌ای از پژوهش‌های انجام شده با استفاده از شبکه‌های عصبی در شاخه‌ی پیش‌بینی سری‌های زمانی اشاره شده است.

وانگ (۲۰۰۹) به تلفیق یک نوع مدل گارچ به نام گارچ گری<sup>۴</sup> اقدام به پیش‌بینی شاخص بورس تایوان کرد و مدل تلفیقی توسعه داده شده توسط آن‌ها توانست بهتر از هر یک از مدل‌های سازنده‌ی مدل تلفیقی آن‌ها عدم تقارن بازده را توضیح دهد [۴۵]. بیلدریسی در همان سال همان مدل وانگ را بر روی بورس ترکیه پیاده‌سازی کرد و پژوهش آن‌ها به شکلی جامع‌تر قدرت این مدل را تصدیق نمود [۵]. حاجی زاده و دیگران (۲۰۱۲) با تلفیق گارچ نمایی و شبکه عصبی، مدلی ساختند که شاخص بورس آمریکا را پیش‌بینی کند. از میان مدل‌های توسعه داده شده، مدلی که از گارچ مرتبه ۳ و ۳ استفاده می‌کرد توانست سایر مدل‌های رقیب را در دقت پیش‌بینی شکست دهد؛ هرچند که در پیش‌بینی داده‌های دارای تلاطم شدید توانمندی کافی را نداشت [۱۷]. بیلدریسی و ارسین مجدداً در سال ۲۰۱۴ مقاله‌ای به چاپ رساندند که در آن یک مدل گارچ و تغییر رژیم را با استفاده از شبکه عصبی تخمین زده است [۶]. در سال ۲۰۱۵ کریست جانپولر و مینوتولو با استفاده از مدل گارچ و شبکه عصبی اقدام به پیش‌بینی شاخص بورس کشورهای شیلی، برزیل و مکزیک کردند. نتایج پژوهش آن‌ها نشان داد که شبکه‌های عصبی به کمک مدل گارچ می‌تواند عملکرد مدل گارچ به تنهایی را بهبود بخشد. آن‌ها نتایج پژوهش شان را با استفاده از تابع میانگین قدرمطلق درصدی خطا مقایسه کردند [۲۵]. بیلدریسی و ارسین این بار مجدداً در مقالیشان همان مدل مقاله

<sup>۱</sup> Recurrent Neural Network

<sup>۲</sup> Multi-Layer Perceptron

<sup>۳</sup> Artificial Intelligence

<sup>۴</sup> Grey



سال ۲۰۱۴ را بر روی داده‌های شاخص طلا در کشور ترکیه پیاده سازی کردند و نتایج پژوهش آن‌ها نشان داد که مدل تغییر رژیم موجب افزایش دقت مدل شبکه عصبی می‌شود [۷]. در سال ۲۰۱۷ مجدداً کریست جانپولر و فرد دیگری به نام هرمانندز با پیاده سازی مدل شان بر روی قیمت طلا، نقره و مس نتیجه پژوهش پیشین که در سال ۲۰۱۵ چاپ شده بود را تأیید کردند. در واقع در این پژوهش آن‌ها در بازه زمانی جامع تر و نوع پیش‌بینی کامل‌تری از نظر تعداد روز پیش‌بینی، برتری مدلی که شبکه‌های عصبی را با مدل گارچ تلفیق می‌کرد، نشان دادند [۲۴]. کیم و وون (۲۰۱۸) با استفاده از شبکه‌های عصبی عمیق اقدام به پیش‌بینی شاخص بورس کره نمودند. آن‌ها روش‌های متفاوت پیش‌بینی از نظر نوع متغیرهای ورودی گارچ را به شبکه با هم مقایسه نمودند و معنی‌داری اختلاف نتایج را با استفاده از آزمون دیابولد ماریانو بررسی کردند [۲۳]. ژوانگ و انکه (۲۰۱۹) با استفاده از شبکه‌های عصبی اقدام به پیش‌بینی داده‌های ETF بر روی بورس آمریکا کردند. در این پژوهش با استفاده از الگوریتم تحلیل مولفه‌های اصلی این فاکتورها را بررسی کرده و به عنوان ورودی به شبکه عصبی دادند. نتیجه پژوهش آن‌ها در نهایت موجب توسعه الگوریتم معاملاتی‌ای شد که بازدهی بیشتر از بازده بازار کسب می‌کرد [۴۶]. وانگ لی، لی ژوانگ لیو (۲۰۲۰) شبکه عصبی عمیقی را برای پیش‌بینی شاخص بورس انگلستان توسعه دادند. نتیجه پژوهش آن‌ها نشان داد که با استفاده از شبکه‌های عصبی و پیش‌انتخاب‌داری‌های با کیفیت، کیفیت بهینه‌سازی سبد سهام افزایش می‌یابد [۴۴]. تا لیو تادیس (۲۰۲۰) با استفاده از شبکه عصبی عمیقی که توسعه دادند اقدام به پیش‌بینی ۵۰۰ سهم از شاخص بورس آمریکا کردند. نتیجه پژوهش آن‌ها نشان داد شبکه عصبی حافظه کوتاه و بلندمدت ماندگار نسبت به رگرسیون خطی و ماشین بردار پشتیبان ۳ عملکرد بهتری در پیش‌بینی داشته که منجر به ارائه یک بهینه‌سازی سبد سهام با کیفیت تر می‌شود [۴۱]. در بورس تهران، در یک مطالعه موردی بر روی قیمت سهام شرکت پالایش نفت اصفهان، بدیعی و دیگران (۱۳۹۶) اقدام به پیش‌بینی قیمت کردند. آن‌ها در پژوهششان از مؤلفه‌های تابلو سهم و همچنین قیمت طلا و ارز استفاده نمودند. نتایج پژوهش آن‌ها نشان داد که مدل‌های شبکه عصبی به شکل معنی‌داری تاثیر متغیرهای کلان اقتصادی را بهتر از مدل‌های چند شاخصی بر قیمت منعکس می‌کنند [۴]. در ادامه باباجانی و دیگران (۱۳۹۸) اقدام به پیش‌بینی سهم‌های بازار بورس تهران با استفاده از شبکه عصبی بازگشتی از نوع المان و الگوریتم بهینه‌سازی کلونی زنبور عسل کردند. در پژوهش آن‌ها هم از متغیرهای بنیادی و هم تکنیکال به صورت همزمان استفاده شده است. نتایج پژوهش آن‌ها نشان داد که شبکه‌های عصبی در صورت بهره بردن از مؤلفه‌های مناسب قابلیت پیش‌بینی بازه کوتاه‌مدت را دارند [۳]. همچنین در پژوهشی دیگر ذولفقاری و دیگران (۱۳۹۹) اقدام با ترکیب مدل‌های گارچ و شبکه‌های عصبی عمیق کرده

<sup>۱</sup> Principal Component analysis

<sup>۲</sup> Asset pre-selection

<sup>۳</sup> Support Vector Machine

و بازده شاخص بورس تهران را پیش‌بینی نمودند. پژوهش آن‌ها نیز نشان داد که شبکه‌های عصبی در پیش‌بینی شاخص موفق عمل میکنند [۲۹]. در نهایت در پژوهشی که به تازگی بررسی شده است امینی‌مهر و دیگران (۱۴۰۰) اقدام به پیش‌بینی قیمت شاخص کل بورس تهران و بررسی تأثیرات روش‌های پیش‌پردازش داده‌ها بر روی دقت پیش‌بینی شبکه‌های عصبی عمیق کردند. نتایج پژوهش آن‌ها نشان داد که شبکه‌های عصبی به کمک تکنیک نوفه‌زدایی موجک قابلیت بهتری برای پیش‌بینی قیمت شاخص دارند [۱].

نکته مهم در این پژوهش، ارتباط مستقیم ساختار مدل تدوین شده با رفتار آماری شناسایی شده داده‌های شاخص بورس تهران می‌باشد. همچنین این پژوهش پس از بررسی کارایی بازار، راجع به قابلیت مدل ارائه شده برای کسب سود مازاد اقدام به آزمون معکوس و شبیه‌سازی معامله کرده است. همچنین نکته‌ی با اهمیتی که در این پژوهش مورد بررسی قرار گرفته، توانایی مدل‌های ارائه شده در پیش‌بینی جهت بازده و تغییر جهت‌های بازده می‌باشد.

### شبکه عصبی احتمال ترکیبی بیشاپ

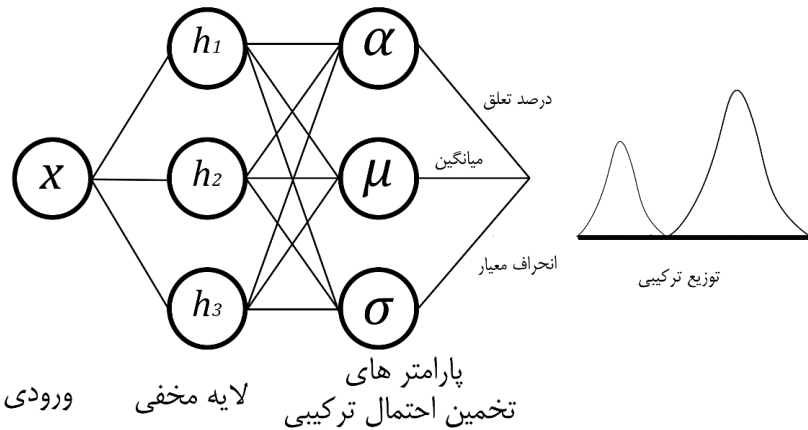
این شبکه عصبی دارای لایه‌های مخفی موازی می‌باشند که هر کدام از این لایه‌ها بر اساس نوع تابع مولد شان و تابع هزینه شبکه میزان تعلق داده‌ی خروجی شبکه را به هر توزیع آماری تخمین می‌زند. علاوه بر آن، در لایه‌های دیگر نیز پارامتر میانگین و واریانس توزیع‌های یافت شده تخمین زده می‌شود. در واقع بیشاپ با استفاده از شبکه عصبی خود تخمینی به شکل رابطه ۱ برآزش نمود.

$$p(y|x) = \sum_{i=1}^m \alpha_i(x) \Phi_i(y|x) \quad \text{رابطه ۱}$$

در این فرمول  $m$  تعداد توزیع‌هایی می‌باشد که برای پاسخ در نظر گرفته شده است. پارامتر  $\alpha_i(x)$  ضریب‌های تلفیق می‌باشند و برابر با احتمال تعلق پاسخ، همان  $\mathcal{Y}$ ، به هر یک از توزیع‌های موجود می‌باشد. باید در نظر داشت که ضریب تلفیق خود تابعی از ورودی شبکه می‌باشد که در این مسئله همان  $x$  است. در نهایت تابع  $\Phi_i(y|x)$ ، تابع چگالی شرطی  $x$  به ازای هر توزیع تعریف شده برای پاسخ می‌باشد. از آن جایی که این توزیع‌های قائل شده گوسی در نظر گرفته شده‌اند، این تابع به صورت رابطه ۲ محاسبه می‌شود.

$$\Phi_i(y, x) = \frac{1}{(2\pi)^{c/2} \sigma_i(x)^c} \exp \left\{ -\frac{\|y - \mu_i(x)\|^2}{2\sigma_i(x)^2} \right\} \quad \text{رابطه ۲}$$

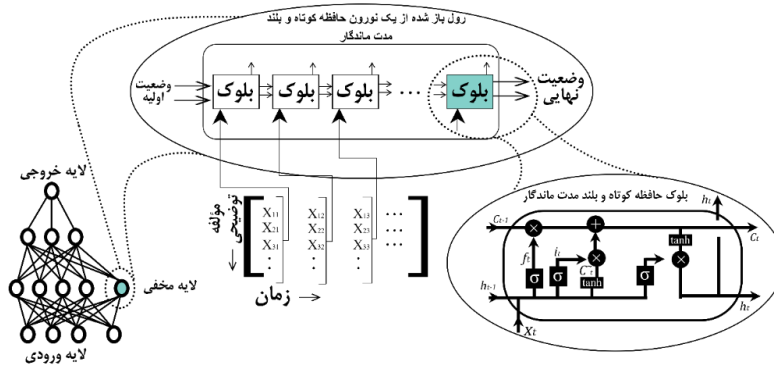
در این شبکه عصبی تابع هزینه در واقع میزان درست‌نمایی تابع چگالی احتمال ترکیبی است. که با لگاریتم‌گیری و منفی کردن آن توسط بهینه‌ساز آدام کمینه می‌شود. معماری شبکه عصبی احتمال ترکیبی به کار رفته در شکل ۱ نشان داده شده است.



شکل ۱. معماری شبکه عصبی احتمال ترکیبی مورد استفاده در این پژوهش

### شبکه‌های عصبی حافظه کوتاه‌مدت و بلندمدت ماندگار

شبکه‌های عصبی حافظه کوتاه‌مدت و بلندمدت ماندگار توسط هوخیدر و شمیت هوپر به عنوان جایگزینی بر روش‌های پیشین خود برای آموزش داده‌های دارای ترتیب وقوعی معرفی شدند [۲۲]. شبکه‌های عصبی حافظه کوتاه و بلندمدت ماندگار از دسته شبکه‌های بازگشتی هستند، اما با این تفاوت که این شبکه توانایی بازیابی اطلاعات طولانی مدت را بیشتر از شبکه‌های عصبی بازگشتی ساده دارند [۱۶، ۲۶]. یکی از دلایل مهمی که از این شبکه در سال‌های اخیر بسیار استقبال شده است، احتمال کمتر اشباع شدن نورون‌ها در حین آموزش نسبت به شبکه‌های بازگشتی ساده می‌باشد. نورون‌های این شبکه‌ها از بلوک‌هایی ساخته شده است که خاصیت حافظه را به این نورون‌ها می‌بخشد. شکل ۲ معماری شبکه عصبی حافظه کوتاه‌مدت و بلندمدت ماندگار به کار رفته در این پژوهش را نشان می‌دهد.



شکل ۲. معماری شبکه عصبی حافظه کوتاه‌مدت و بلندمدت ماندگار مورد استفاده در این پژوهش

فرمول توابع داخل هر بلوک شبکه حافظه کوتاه و بلندمدت ماندگار به شرح زیر می‌باشد:

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad \text{رابطه ۳}$$

$$i_t = \sigma(w_{i2} [h_{t-1}, x_t] + b_i) \quad \text{رابطه ۴}$$

$$O_t = \sigma(W_0 \cdot [h_{t-1}, x_t] + b_0) \quad \text{رابطه ۵}$$

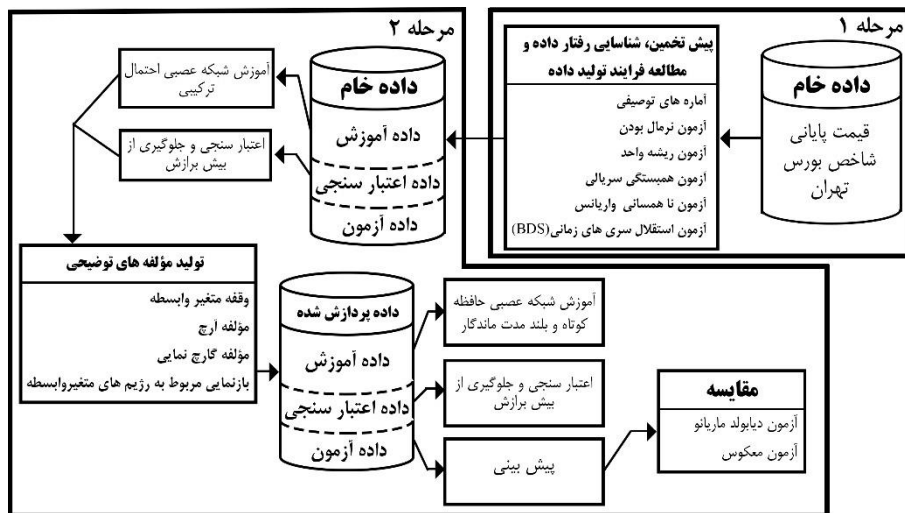
$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad \text{رابطه ۶}$$

$$g_t = \tanh(x_t U^g + h_{t-1} W^g) \quad \text{رابطه ۷}$$

$$h_t = \tanh(c_t) \cdot 0 \quad \text{رابطه ۸}$$

### ۳. روش شناسی پژوهش

این پژوهش با نگاهی آماری بر داده‌های شاخص کل بورس تهران اقدام به شناسایی رفتار و فرآیند تولید داده‌های بازده روزانه شاخص کرده است. این امر بدین منظور انجام می‌شود که پژوهشگران علاقه مند به پیش‌بینی ساختار خطی، غیر خطی و یا آشوبی داده‌های بازده بورس تهران را شناسایی کرده و علاوه بر آن نسبت به کارایی ضعیف‌این بازار آگاه شوند. همچنین پس از انجام آزمون‌های متعدد و شناسایی رفتار این داده‌ها و اظهار نظر راجع به کارایی این بازار، مدلی با استفاده از دو شبکه عصبی جهت پیش‌بینی، معرفی و پیاده‌سازی شده است. هدف از این توسعه، بررسی امکان پیش‌بینی بازده شاخص بورس تهران و کسب سود اضافی از آن با استفاده از مدلی که با توجه به ساختار آماری شاخص این بازار تدوین شده است، می‌باشد. در این جهت، به داده‌های بازدهی روزانه شاخص بورس تهران در بازه زمانی آذر ۱۳۸۷ تا فروردین ۱۴۰۰ که شامل داده‌های روزانه مربوط به ۲۹۷۴ مقطع زمانی می‌باشد، پرداخته شده است. داده‌های این پژوهش که فقط شامل قیمت پایانی روزانه تاریخی شاخص کل بورس تهران می‌باشد، از سایت `tsetmc` دریافت شده است. در این پژوهش جهت مدل‌سازی از زبان برنامه نویسی پایتون و کتابخانه‌های مربوط به هوش مصنوعی و داده کاوی استفاده شده است. از جمله کتابخانه‌های استفاده شده می‌توان بر `tensorflow`, `keras`, `scipy`, `math`, `statstools`, `numpy`, `matplotlib`, `seaborn` اشاره نمود. شکل شماره (۳) فلو چارت مراحل انجام این پژوهش را نشان می‌دهد. در این فلو چارت به شکل مختصر تمام مراحل انجام این پژوهش، از دریافت داده تا مرحله‌ی نهایی یعنی مقایسه مدل‌های ارائه شده را نشان می‌دهد. لازم به ذکر می‌باشد که روش این پژوهش بنا بر دو هدف اصلی که دنبال می‌کند، یعنی بررسی کارایی بازار و ارائه مدل پیش‌بینی به دو مرحله متوالی تقسیم می‌شود. در فلو چارت نشان داده شده، قسمت‌های مربوط به هر مرحله روش پژوهش به شکل مجزا مشخص شده است.



شکل ۳. فلو چارت روش انجام پژوهش پیش‌بینی و مراحل انجام آزمون‌ها و پیاده‌سازی مدل پیش‌بینی

#### ۴. تحلیل داده‌ها و یافته‌ها

##### مرحله ۱

در بررسی مانایی سری بازده شاخص بورس تهران از آنجایی که آزمون ADF با در نظر گرفتن شیب و عرض از مبدا فرض داشتن ریشه واحد را در سطح اطمینان ۹۵ درصد نمود دیگر نیاز به مرحله‌های بعدی آزمون ریشه واحد نیست، اما آزمون Jarque-Bera فرض نرمال بودن سری بازده را رد می‌کند. با توجه به آماره‌های توصیفی به دست آمده مشخص است که سری بازده دارای یک توزیع با اکسترم‌های ضخیم<sup>۱</sup> است و نشان دهنده رفتار خوشه‌ای توزیع بازده شاخص بورس تهران است. موارد ذکر شده در جدول (۱) نشان داده شده است. همچنین نمودار چگالی احتمال بازده شاخص در شکل (۵) نشان داده شده است.

جدول ۱. آمار توصیفی به همراه آزمون نرمال بودن و ریشه واحد بر روی سری بازده شاخص بورس تهران

| آمار توصیفی  | میانگین | انحراف معیار | چوایی  | کشیدگی | آماره آزمون جاکوبو | آماره آزمون ریشه واحد |
|--------------|---------|--------------|--------|--------|--------------------|-----------------------|
| بازده روزانه | ۰/۰۰۱۷  | ۰/۰۱۰۳       | ۰/۳۳۸۵ | ۶/۹۱۰۶ | ۱۹۵۱/۹             | -۱۷                   |
| قیمت         |         |              |        |        |                    |                       |

برای بررسی کارایی، از آزمون همبستگی سریالی بر روی بازده شاخص بورس تهران استفاده شده است. نتایج آزمون نشان از وجود حافظه در داده‌های بازده شاخص بورس تهران می‌دهد.

<sup>۱</sup> Fat tail

همچنین برای بررسی بیشتر رفتار خوشه‌ای بازده از آزمون Arch-LM استفاده شده است که نتیجه آن نشان داد در سری بازده ناهمسانی واریانس وجود دارد.

در ادامه شناسایی رفتار داده‌های بورس تهران از آزمون BDS استفاده می‌شود. اهمیت برگزاری این آزمون در این است که نشان می‌دهد که آیا داده‌های بازده کاملاً تصادفی و مستقل و یکسان هستند یا خیر. همچنین در صورتی که این فرض رد شود می‌توان به بررسی خطی، غیر خطی یا آشوبی<sup>۱</sup> بودن فرایند تولید سری بازده با استفاده از همین آزمون پرداخت.

در انجام این آزمون نکات بسیار مهمی وجود دارد که نیاز است پژوهشگران به آن توجه کنند. اولاً این که برای بررسی ذات داده‌ها نیاز است که این آزمون در مراحل متفاوت انجام شود. در مرحله اول این آزمون بر روی داده‌های بازده پیاده شده و نتیجه حاصل شده تحلیل می‌شود. اگر فرضیه صفر این آزمون در این مرحله رد نشود به این معنی است که داده‌های بازده دارای توزیع مستقل و یکسان بوده یا همان رفتار نوفه سفید را دارد. بنابراین برآزش مدل پیش‌بینی بر روی آن کارکردی ندارد و قابلیت استخراج دانش از میان آن داده‌ها وجود ندارد و در این صورت بررسی متوقف شده و دیگر مرحله‌ای وجود نخواهد داشت. اما اگر در این مرحله فرض صفر رد شود به این معنی می‌باشد که در میان این داده‌ها دانشی وجود دارد که البته ذات خطی یا غیر خطی بودن آن هنوز مشخص نیست. بنابراین نیاز است که مطالعه ادامه پیدا کند. در این مرحله با استفاده از یک مدل برآزش خطی سعی بر استخراج دانش موجود میان داده‌ها می‌شود. پس از انجام تخمین خطی آزمون BDS مجدد بر روی داده‌های پسماند تخمین برگزار می‌شود. در صورتی که نتیجه آزمون بر روی این داده‌ها نشان از توزیع مستقل و یکسان بدهد، بدین معنی می‌باشد که دانش موجود در داده‌های بازده‌ی خطی بوده است و مدل خطی توانسته آن را استخراج کند و دانشی در سری پسماند باقی نمانده است. در این حال بررسی متوقف شده و به ذات داده‌های بازده خطی اطلاق می‌شود. اما در صورتی که در این آزمون نیز فرض صفر رد شود، مرحله‌ای دیگر به تحلیل اضافه خواهد شد. این حالت به این معنی است که دانش موجود در بازده با یک تخمین خطی قابل استخراج نبوده و احتمالاً روابط موجود در آن پیچیده تر است. در این حال مجدداً بر روی داده‌های بازده یک تخمین برآزش می‌شود اما این بار با استفاده از یک مدل غیر خطی. پس از انجام این تخمین مجدداً آزمون BDS از داده‌های پسماند گرفته می‌شود. در صورتی که فرض صفر رد نشود در واقع ذات داده‌ها غیر خطی بوده و توسط مدل خطی توضیح داده شده است و دیگر دانشی در داده‌ها باقی نمانده است. در غیر این صورت گفته می‌شود که دانشی در داده‌ها وجود دارد و رفتار آن (در این مثال داده‌های بازده) آشوبی بوده و مدل‌های غیر خطی توان برآزش و توضیح آن را ندارد.

در انجام آزمون BDS فاکتور مهمی وجود دارد که باید به آن توجه کرد. در این آزمون تشخیص میزان  $\epsilon$  بسیار مهم است. نکته مهم این است که بهتر است این عدد بزرگ‌ترین عدد کوچکتر از

<sup>۱</sup> Chaotic

۱ و ضریبی از واریانس سری زمانی باشد که آزمون بر روی آن انجام می‌شود. در واقع بزرگ‌ترین عددی که این ویژگی را داشته باشد به عنوان  $\varepsilon$  در نظر گرفته می‌شود در صورتی که فرض صفر رد نشود به  $\varepsilon$  با حفظ شرایطی که برای آن مطرح شد اعداد کوچک تری اطلاق می‌شود و آزمون مجدد برگزار می‌شود. اگر در نهایت فرض صفر رد نشد سری مورد نظر قویاً نوفه سفید می‌باشد در حین این گام‌ها در هر مرحله‌ای اگر فرض صفر رد شود به معنی رد شدن فرض صفر است و دیگر نیاز به ادامه گام‌ها نیست. نتایج پیاده سازی آزمون BDS بر روی داده‌های سری بازده در جدول (۲) تا (۴) نشان داده شده است.

جدول ۲. نتایج آزمون BDS بر روی سری بازده شاخص بورس تهران

| آزمون BDS بر روی سری بازده شاخص بورس تهران |           |              |          |        |
|--|-----------|--------------|----------|--------|
| بعد  | آماره BDS | انحراف معیار | آماره Z  | احتمال |
| ۲  | ۰/۰۰۵۷۳۷  | ۰/۰۰۰۲۰۱     | ۲۸/۵۷۶۲۸ | ۰/۰۰۰۰ |
| ۳  | ۰/۰۰۲۳۳۵  | ۰/۰۰۰۰۵۰۷    | ۴۶/۰۴۹۱۷ | ۰/۰۰۰۰ |
| ۴  | ۰/۰۰۰۷۲۲  | ۰/۰۰۰۰۰۹۶    | ۷۴/۶۷۱۹۷ | ۰/۰۰۰۰ |
| ۵  | ۰/۰۰۰۲۰۲  | ۰/۰۰۰۰۰۱۶۲   | ۱۲۴/۷۴۹۸ | ۰/۰۰۰۰ |
| ۶  | ۰/۰۰۰۰۵۱۸ | ۰/۰۰۰۰۰۰۲۵۲  | ۲۰۵/۲۵۸۰ | ۰/۰۰۰۰ |

جدول ۳. نتایج آزمون BDS بر روی سری پسماند یک برازش خطی بر روی بازده شاخص بورس تهران

| آزمون BDS بر روی پس ماند مانده تخمین مدل خطی بر روی بازده شاخص بورس تهران |           |              |          |        |
|---|-----------|--------------|----------|--------|
| بعد   | آماره BDS | انحراف معیار | آماره Z  | احتمال |
| ۲   | ۰/۰۲۲۴۷۵  | ۰/۰۰۱۲۸۲     | ۱۷/۵۲۸۹  | ۰/۰۰۰۰ |
| ۳   | ۰/۰۶۱۶۲۳  | ۰/۰۰۲۴۷۲     | ۲۴/۹۳۰۳۵ | ۰/۰۰۰۰ |
| ۴   | ۰/۱۰۵۸۴۷  | ۰/۰۰۳۵۶۸     | ۲۹/۶۶۱۵۸ | ۰/۰۰۰۰ |
| ۵   | ۰/۱۴۶۴۳۸  | ۰/۰۰۴۵۲۸     | ۳۲/۴۸۳۷  | ۰/۰۰۰۰ |
| ۶   | ۰/۱۸۲۸۹۱/ | ۰/۰۰۵۲۶۸     | ۳۴/۷۱۴۷  | ۰/۰۰۰۰ |

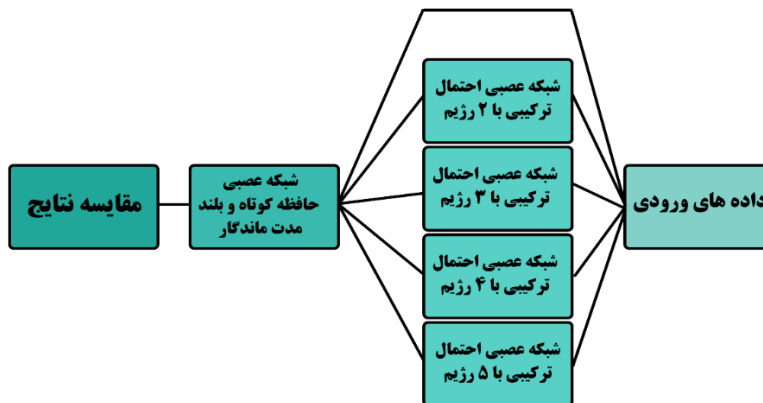
جدول ۴. نتایج آزمون BDS بر روی سری پسماند یک برازش غیرخطی بر روی بازده شاخص بورس تهران

| آزمون BDS بر روی سری پس ماند تخمین مدل غیر خطی بر روی بازده شاخص بورس تهران |           |              |           |        |
|---|-----------|--------------|-----------|--------|
| بعد   | آماره BDS | انحراف معیار | آماره Z   | احتمال |
| ۲   | ۰/۰۰۵۷۳۷  | ۰/۰۰۰۲۰۱     | ۲۸/۵۷۶۲   | ۰/۰۰۰۰ |
| ۳   | ۰/۰۰۲۳۳۵  | ۰/۰۰۰۰۵۰۷    | ۴۶/۰۴۹۱   | ۰/۰۰۰۰ |
| ۴   | ۰/۰۰۰۷۲۲  | ۰/۰۰۰۰۰۹۶۶   | ۷۴/۶۷۱۹   | ۰/۰۰۰۰ |
| ۵   | ۰/۰۰۰۲۰۲  | ۰/۰۰۰۰۰۰۱۶۲/ | ۱۲۴/۷۴۸۹/ | ۰/۰۰۰۰ |
| ۶   | ۰/۰۰۰۰۵۱۸ | ۰/۰۰۰۰۰۰۲۵۲  | ۲۵۰/۲۵۸۰  | ۰/۰۰۰۰ |

بنا بر نتایجی که از آزمون BDS، آزمون Jaque-bera، آزمون Arch-LM و سایر آزمون‌های انجام شده بر روی بازده به دست آمد، مشخص است که داده‌های سری بازده شاخص بورس تهران دارای رفتار آشوبی است و فرض نوفه سفید بودن و مستقل و یکسان بودن آن رد می‌شود.

## مرحله ۲

در این قسمت به بررسی مدل پیش‌بینی پیاده‌سازی شده پرداخته می‌شود. فلوجارت نشان داده شده در شکل ۴ مقایسه انجام شده در آزمایش‌های این قسمت را نشان می‌دهد.



شکل ۴. فلوجارت مقایسه انجام شده در مرحله دوم پژوهش

داده‌های این پژوهش به سه قسمت داده‌های آموزش<sup>۱</sup>، داده‌های اعتبار سنجی<sup>۲</sup> و داده‌های آزمون<sup>۳</sup> تقسیم شده‌اند. داده‌های آموزش شامل ۲۰۸۰ نقطه زمانی (۱۷ آذر ۱۳۸۷ تا ۳ مرداد ۱۳۹۶) ، داده‌های اعتبار سنجی شامل ۷۰۰ نقطه (۴ مرداد ۱۳۹۶ تا ۱ تیر ۱۳۹۹) و داده‌های آزمون شامل ۱۹۴ نقطه (۲ تیر ۱۳۹۹ تا ۱۸ فروردین ۱۴۰۰) است. لازم به ذکر است که تا بعد از دریافت خروجی‌های شبکه عصبی اول هیچ یک از داده‌ها از جمله متغیرهای مستقل و وابسته تغییر مقیاس داده نشدند. صرفاً پس از دریافت خروجی شبکه اول متغیر وابسته به مقیاس ۱- تا ۱ انتقال یافته است.

شبکه عصبی اول (احتمال ترکیبی) در واقع به دنبال کمینه کردن مقدار منفی لگاریتم تابع چگالی احتمال توزیع ترکیبی گوسی بوده است، و پس از اتمام روند آموزشش خروجی‌های مربوط به لایه‌های میانگین، واریانس و درصد تعلق به هر توزیع به شبکه بعدی داده می‌شود. در واقع کار شبکه عصبی اول در سیستم ارائه شده، ایجاد بازنمایی‌های آماری مطابق با دسته بندی رژیم‌های

<sup>۱</sup> Training data

<sup>۲</sup> Validation data

<sup>۳</sup> Test data



مدل‌سازی شده است. پس از دریافت بازنمایی‌ها، این فاکتورها در کنار فاکتورهای وقفه متغیر وابسته، ARCH و GARCH به مدل شبکه عصبی حافظه کوتاه و بلندمدت ماندگار به عنوان مؤلفه ورودی داده می‌شود.

در آموزش شبکه عصبی احتمال ترکیبی استفاده شده در این پژوهش، در لایه اول مخفی از ۲۰۰ نورون استفاده شده است. این لایه به طور همزمان به سه لایه متصل می‌شود. البته قبل از انتقال داده‌ها به لایه‌های موازی بعد، از یک تابع مولد غیر خطی تانژانت‌هایپربولیک<sup>۱</sup> عبور داده می‌شوند. سه لایه موازی بعد به شرح زیر هستند.

یک لایه برای تخمین میانگین که در این لایه بسته به این که در مدل داده‌ها قرار است به چند رژیم رفتارشان دسته بندی شود، از همان تعداد نورون استفاده شده است. به طور مثال اگر قرار است که داده‌های بازده رفتارشان در چارچوب پارامترهای ۲ توزیع آماری (رژیم) توضیح داده شود از دو نورون در این لایه استفاده می‌شود. در این لایه از یک تابع مولد ریلو<sup>۲</sup> استفاده شده است.

لایه موازی دیگری برای واریانس در نظر گرفته شده است. از آنجایی که خروجی‌های این لایه نمی‌توانند منفی باشند آن را مجدد به یک لایه دیگر که در آن داده‌های لایه واریانس را نمای می‌کند، داده می‌شود. در لایه واریانس از تابع فعال ساز غیر خطی استفاده نشده است و داده‌های خروجی از لایه واریانس مستقیماً به لایه نمایی کننده انتقال می‌یابند. تعداد نورون استفاده شده در این لایه با توجه به تعداد رژیم‌های در نظر گرفته شده انتخاب می‌شود.

لایه موازی دیگری وجود دارد که تخمین زننده میزان تعلق هر داده ورودی به هر یک از توزیع‌های مولد مورد نظر، است. از آنجایی که خروجی‌های این لایه بیان کننده درصد تعلق داده‌ها به هر یک از توزیع‌ها است، باید جمع خروجی‌ها ۱ شود. بنابراین از تابع مولد سافت مکس<sup>۳</sup> استفاده شده است. تعداد نورون‌های این لایه نیز همچون دو لایه موازی با آن، برابر با تعداد توزیع‌هایی است که داده‌ها قرار است به تعداد آن‌ها دسته بندی شوند.

شبکه عصبی حافظه کوتاه و بلندمدت ماندگاری که در این پژوهش برآزش شده است دارای سه لایه مخفی است. در لایه مخفی اول شبکه از ۶ نورون استفاده شده است. در این لایه از تابع مولد ریلو نشستی<sup>۴</sup> به عنوان تابع مولد اصلی و همچنین به عنوان تابع مولد بازگشتی استفاده شده است. دلیل استفاده از ریلو نشستی در این لایه کمتر بودن احتمال اشباع این تابع مولد و عدم اشباع برای مقادیر منفی است که با توجه به عمیق بودن نسبی شبکه و موقعیت این لایه بخصوص، مناسب ارزیابی شده است. در لایه دوم مخفی این شبکه از ۳۰ نورون حافظه کوتاه و بلندمدت ماندگار استفاده شده است. در این لایه با توجه به احتمال کمتر اشباع شدن گرادبان از تابع مولد

<sup>۱</sup> tanh

<sup>۲</sup> Relu

<sup>۳</sup> SoftMax

<sup>۴</sup> Leaky Relu

تانژانت‌های ریپولیک استفاده شده است. از طرفی استفاده از ریلو در این لایه باعث می‌شود که تابع گرادین بسیار از مینیمم‌ها را رد کرده و از جستجوی بهینه‌ی فضای گرادین این مسئله به خصوص به اندازه کافی دقت کسب نکند. به عنوان تابع مولد بازگشتی در این شبکه از تابع سیگموئید<sup>۱</sup> استفاده شده است که آزمون و خطاهای مکرر، این ترکیب را برای این لایه مناسب ارزیابی کرد. در لایه سوم مخفی مجدد از ۶ نورون استفاده شده است. در لایه خروجی از یک نورون ساده با تابع فعال ساز خطی استفاده شده است.

پس از هر لایه مخفی شبکه عصبی حافظه کوتاه و بلندمدت ماندگار از یک لایه Dropout استفاده شده است. این لایه با نرخ‌های که برای آن مشخص شده، به حذف تصادفی نورون‌ها در حین آموزش شبکه می‌پردازد. این تکنیک توسط ساریویستا و دیگران [۴۰] اولین بار معرفی شده است و از بیش‌برازش<sup>۲</sup> شدن شبکه جلوگیری می‌کند.

انتخاب نرخ یادگیری<sup>۳</sup> مناسب برای آموزش شبکه‌هایی که از بهینه‌ساز آدام استفاده می‌کنند بسیار مهم و در عین حال می‌تواند چالش برانگیز باشد. نرخ یادگیری خیلی کم باعث می‌شود که شبکه روند یادگیری را بسیار کند طی نماید و در اکثر مواقع در مینیمم‌های محلی<sup>۴</sup> به دام می‌افتد. در مقابل، استفاده از نرخ یادگیری بالا باعث می‌شود که شبکه دچار انفجار گرادین<sup>۵</sup> شود [۴۳]. برای انتخاب نرخ مناسب یادگیری روش مشخصی وجود ندارد و اغلب پژوهشگران از روش‌های ابتکاری و بعضاً آزمون و خطا استفاده می‌کنند. در این پژوهش اما، برای یافتن نرخ مناسب یادگیری از تکنیک callback استفاده شده است. در این تکنیک ابتدا شبکه با استفاده از یک تابع callback طوری آموزش داده می‌شود که در هر تکرار نرخ یادگیری تغییر داده می‌شود. این تغییر به گونه‌ای است که بازه‌ای از اعداد پوشش داده شود. نرخ آموزشی که کمترین میزان خطا را کسب کرده باشد به عنوان نرخ آموزش ثابت انتخاب شده و شبکه مجدد آموزش می‌بیند. همچنین برای جلوگیری از بیش‌برازش شدن شبکه از تابع callback مخصوص توقف آموزش هنگامی که خطای داده‌های اعتبار سنجی کاهش نیابد، استفاده شده است.

تابع هزینه:

توابع هزینه استفاده شده در سنجش دقت مدل‌های پیش‌بینی ارائه شده به شرح روابط زیر است.

$$MSE = \frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2 \quad \text{رابطه ۸}$$

$$MAE = \frac{\sum_{i=1}^n |A_t - F_t|}{n} \quad \text{رابطه ۹}$$

<sup>۱</sup> Sigmoid

<sup>۲</sup> Overfitting

<sup>۳</sup> Learning rate

<sup>۴</sup> Local minimum

<sup>۵</sup> Exploding gradient

علاوه بر توابع هزینه‌ای که به صورت عمومی در مسائل رگرسیون استفاده می‌شوند، در مسائل پیش‌بینی بازده دارایی‌ها [۳۴] دو معیار ارزیابی برای عملکرد مدل‌های پیش‌بینی ارائه دادند. این معیارها هر کدام دقت علامت پیش‌بینی (CSP<sup>۱</sup>) و دقت تغییر علامت پیش‌بینی شده (CDCP<sup>۲</sup>) را می‌سنجند. الگوریتم ریاضیاتی این دو معیار سنجش به صورت زیر است.

$$CDCP = \frac{1}{T - (T_y - 1)} \sum_{t=T_1}^T z_{t+s} \quad \text{رابطه ۱۰}$$

**IF**  $(A_{t+s} - A_t)(F_{t,s} - A_t) > 0$  ; **THEN:**  $z_{t+s} = 1$   
**ELSE:**  $z_{t+s} = 0$

$$CSP = \frac{1}{T - (T_y - 1)} \sum_{t=T_1}^T z_{t+s} \quad \text{رابطه ۱۱}$$

**IF**  $(A_{t+s})(F_{t,s}) > 0$  ; **THEN:**  $z_{t+s} = 1$   
**ELSE:**  $z_{t+s} = 0$

در تمامی فرمول‌های مربوط به این قسمت  $F_t$  نماد ارزش‌های پیش‌بینی شده است و  $A_t$  نماد ارزش واقعی متغیر وابسته می‌باشد.

آنچه که تا به حال ذکر شد مشخصات عمومی مدل‌های پیاده سازی شده بود، در ادامه به بررسی نتایج حاصل از مدل‌ها در ۵ آزمون پرداخته شده است. در آزمایش اول شبکه عصبی حافظه کوتاه و بلندمدت ماندگار بدون استفاده از بازنمایی‌های حاصل از شبکه عصبی احتمال ترکیبی آموزش می‌بیند. در واقع در این شبکه فقط از فاکتورهای وقفه متغیر وابسته، ARCH و GARCH نمایی استفاده شده است. این فاکتورها توانستند شبکه را تا ۵۱ مرتبه تکرار آموزش دهند و بعد از آن دقت شبکه بر روی داده‌های اعتبار سنجی رو به کاهش گذاشته که در این حالت آموزش شبکه به صورت خودکار متوقف می‌شود.

در آزمایش دوم ابتدا داده‌ها را با فرض پیروی از دو رژیم شبکه عصبی تلفیقی گوسی، آموزش می‌دهند. سپس خروجی‌های این شبکه که از ۳ نوع میانگین، واریانس و درصد تعلق هستند، پیش‌بینی می‌شود. این مقادیر پیش‌بینی شده از آنجایی که متعلق به دو رژیم است حاوی ۶ سری زمانی بوده (۳\*۲) و به مدل پیش‌بینی حافظه کوتاه و بلندمدت ماندگار داده می‌شود. در کنار این فاکتورها، همان فاکتورهای ARCH، GARCH و وقفه متغیر وابسته‌ای که به مدل قبلی داده شده بود، داده می‌شود. این داده‌ها شبکه را ۵۷ مرتبه آموزش دادند.


<sup>۱</sup> Correct Sign Prediction

<sup>۲</sup> Correct Direction Change Prediction

در آزمایش سوم شبکه عصبی احتمال ترکیبی گوسی با فرض تبعیت داده‌های بازده شاخص بورس تهران از ۳ رژیم آموزش می‌بیند. در این آزمایش مجموعاً ۹ سری به عنوان بازنمایی‌های توضیح دهنده‌ی رفتار بازده، در کنار مؤلفه‌هایی که به صورت مشترک در آزمایش ۱ و ۲ به شبکه عصبی حافظه کوتاه و بلندمدت ماندگار داده شده بود، به شبکه عصبی بازگشتی حافظه کوتاه و بلندمدت ماندگار این مدل داده می‌شود.

در آزمایش بعد همانطور که تا به حال انجام شد یک رژیم دیگر اضافه شده و مدل شبکه عصبی اول آموزش می‌بیند. این بار ۱۲ سری به عنوان بازنمایی تغییرات رژیم به شبکه عصبی دوم داده شده و شبکه دوم آموزش می‌بیند. در نهایت با استفاده از وزن‌های آموزش دیده از شبکه برای پیش‌بینی استفاده شده است.

در نهایت در آزمایش پنجم ابتدا مدل با فرض تبعیت داده‌ها از ۵ رژیم رفتاری آموزش می‌بیند و خروجی مدل که مجموعاً ۱۵ عدد سری است همراه با سایر مؤلفه‌های مشترک بین مدل‌ها به شبکه عصبی حافظه کوتاه و بلندمدت ماندگار داده می‌شود. در نهایت نتیجه مربوط به پیش‌بینی بر روی داده‌های دیده نشده در شکل ۵ رسم شده است.



شکل ۵: نمودار پیش‌بینی شده توسط مدل ۵ رژیم و مقادیر واقعی رخ داده

همانطور که در جدول (۵) نشان داده شده است، اولاً تمامی مدل‌هایی که دارای بازنمایی مربوط به رژیم داده‌های بازده شاخص بورس تهران هستند دقت بیشتر در پیش‌بینی بازده بر روی داده‌های آزمون کسب نموده‌اند. این امر نشان می‌دهد که توسعه مدل‌های پیش‌بینی از نظر برازش بازنمایی‌هایی مربوط رژیم رفتار داده‌ها می‌تواند در جهت افزایش دقت پیش‌بینی مؤثر واقع شود. در میان مدل‌های پیش‌بینی که بازنمایی رژیم را سنجیده‌اند، مدل دارای دو رژیم از نظر معیار جهت پیش‌بینی همراه با مدل دارای ۵ رژیم در صدر قرار دارند اما از نظر سنجش تغییر جهت پیش‌بینی از مدل ۵ ام بهتر عمل کرده است. از نظر معیار میانگین مجذور خطا و میانگین قدر مطلق خطا مدل شماره (۳) که دارای ۳ رژیم بوده بهترین دقت را در پیش‌بینی داده‌های دیده نشده کسب کرده است.

جدول ۵. نتایج دقت برازش مدل حافظه کوتاه و بلندمدت ماندگار در آزمایش‌ها بر روی داده‌های آزمون

| داده‌های آزمون | تعداد رژیم | شبکه عصبی حافظه کوتاه و بلندمدت ماندگار |          |               |             |
|----------------|------------|---|----------|---------------|-------------|
|                |            | CDCP                                    | CSP      | MAE           | MSE         |
| آزمایش ۱       | -          | ۰/۶۵۱۰۴۱                                | ۰/۴۹۴۷۹۱ | ۰/۰۱۶۱۴۲۸۴۳   | ۰/۰۰۰۳۹۴۴۴۱ |
| آزمایش ۲       | ۲          | ۰/۶۷۱۸۷۵                                | ۰/۶۵۱۰۴۱ | ۰/۰۱۵۴۱۹۳۷۵   | ۰/۰۰۰۳۵۹۴۲۳ |
| آزمایش ۳       | ۳          | ۰/۶۶۶۶۶۶                                | ۰/۶۱۹۷۹۱ | ۰/۰۱۵۳۸۱۷۶۴۲۰ | ۰/۰۰۰۳۵۷۶۲۸ |
| آزمایش ۴       | ۴          | ۰/۶۷۱۸۷۵                                | ۰/۶۴۵۸۳۳ | ۰/۰۱۵۵۳۱۲۱۸   | ۰/۰۰۰۳۶۹۳۶۴ |
| آزمایش ۵       | ۵          | ۰/۶۶۶۶۶۶                                | ۰/۶۵۱۰۴۱ | ۰/۰۱۵۴۳۷۷۴۸   | ۰/۰۰۰۳۵۸۷۹۵ |

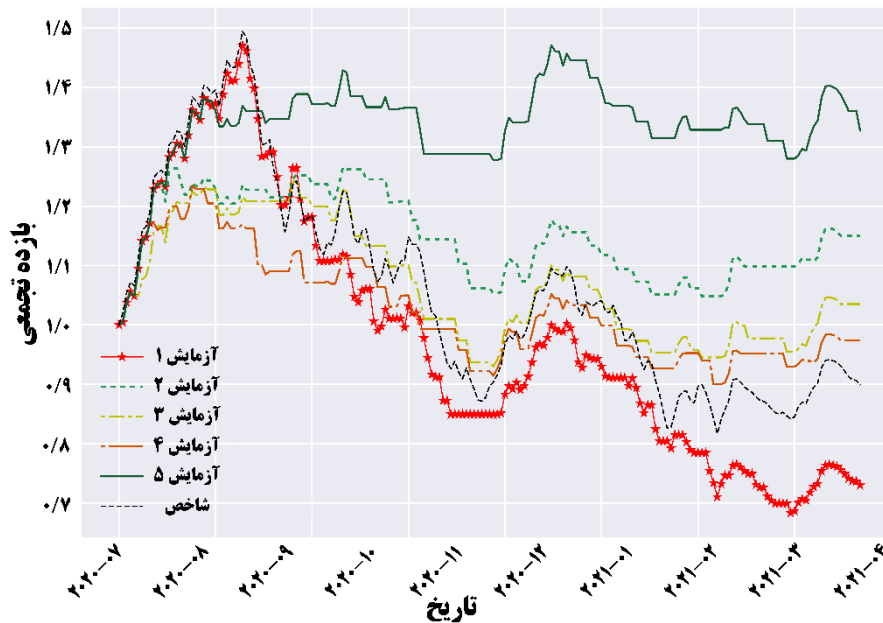
برای بررسی معنی‌دار بودن تفاوت دقت پیش‌بینی مدل‌های بررسی شده از آزمون دیابولد ماریانو<sup>۱</sup> استفاده شده است. این آزمون با استفاده از معیارهای سنجش خطا از جمله میانگین مجذور خطا و میانگین قدر مطلق خطا معنی‌دار بودن تفاوت دقت پیش‌بینی را در مدل‌های ارزیابی شده بر روی داده‌های آزمون می‌سنجد. جدول ۶ نتیجه بررسی آزمون دیابولد ماریانو را نشان می‌دهد. با توجه به این جدول می‌توان نتیجه‌گیری کرد که تفاوت دقت پیش‌بینی مدل‌هایی که داده‌های بازده را به رژیم‌های متفاوت دسته‌بندی کرده و پیش‌بینی را انجام داده‌اند و مدلی که این دسته‌بندی رژیم را انجام نداده است، معنی‌دار بوده و این تفاوت از نظر آماری در سطح اطمینان ۹۵ درصد، صفر نیست. از طرفی تفاوت دقت پیش‌بینی مدل‌هایی که دسته‌بندی رژیم را انجام داده‌اند و صرفاً از نظر تعداد رژیم‌هایی لحاظ شده متفاوت هستند معنی‌دار نبوده و صفر می‌باشد.

جدول ۶. نتایج آزمون دیابولد ماریانو (مقادیر کمتر از ۰/۰۵ به معنی، معنی‌دار بودن اختلاف دقت پیش‌بینی جفت مدل‌های برازش شده می‌باشد)

| آزمون دیابولد ماریانو - مقادیر احتمال | آزمایش ۱ | آزمایش ۲ | آزمایش ۳ | آزمایش ۴ | آزمایش ۵ |
|---------------------------------------|----------|----------|----------|----------|----------|
| آزمایش ۱                              | ۰/۰۰۰۶   | ۰/۰۰۱    | ۰/۰۰۵    | ۰/۰۰۴    |          |
| آزمایش ۲                              |          | ۰/۷۵۸۰   | ۰/۴۴۸۳   | ۰/۸۹۱۸   |          |
| آزمایش ۳                              |          |          | ۰/۳۱۱۸   | ۰/۷۶۶۷   |          |
| آزمایش ۴                              |          |          |          | ۰/۵۸۳۲   |          |

<sup>۱</sup> Diebold Mariano

در انتها برای آنکه به شکلی کاربردی تر به مقایسه قدرت پیش بینی مدل های ارائه شده در این پژوهش پرداخته شود، به انجام آزمون معکوس<sup>۱</sup> با در نظر گرفتن هزینه معاملاتی پرداخته شده است. در این آزمون با استفاده از استراتژی مبتنی بر جهت پیش بینی هر یک از مدل های مقایسه شده در این پژوهش، طی بازه زمانی داده های آزمون، یعنی از دوم تیر ماه سال ۱۳۹۹ تا هجدهم فرودین ماه ۱۴۰۰ معامله شده و نتیجه بازده تجمعی هر یک از این استراتژی ها در شکل (۶) ارائه شده است.



شکل ۶. بازده تجمعی حاصل شده از استراتژی های پیش بینی ارائه شده و شاخص کل

## ۵. بحث و نتیجه گیری

بازار بورس تهران به عنوان یک بازار در حال توسعه فرصت بسیار مناسبی برای سرمایه گذاری است. با توجه به گفته های فاما و تعدیلاتی که لو نسبت به نظریه ایشان داشتند شاخص بورس تهران نیز همچون هر بازار در حال توسعه دیگری دائماً در حال حرکت به سمت کارایی نوع ضعیف است. اگر چه با توجه با آزمون های آماری انجام شده در این پژوهش وجود روابط آشوبی در آن قابل مشاهده بود و توضیح بازده خواص نوفه سفید را نداشت. در ادامه نتایج هم، قابلیت کسب سود مازاد بر شاخص به کمک مدل یادگیری عمیق ارائه شده، نشان داده شد. هم این موارد نشان دهنده

<sup>۱</sup> Back test

ی‌این هستند که در داده‌های تاریخی بازده شاخص بورس تهران دانشی وجود دارد که اگر چه با برخی مدل‌های ساده تر ممکن است قابل استخراج نباشند، اما دلیل بر عدم وجود این روابط نیست. در این پژوهش به صورت جامع مراحل شناخت رفتار داده‌های بازار بورس تهران با استفاده از آزمون‌های متعدد طی شده و ذات آشوبی و توزیع خوشه‌ای در آن شناسایی شده است. از این رو با داشتن یک شناخت کافی و مرور مدل‌های متفاوت با استفاده از کنار هم قرار دادن دو شبکه عصبی اقدام به مدل‌سازی رفتار بازده شاخص بورس تهران شده است. نتایج نشان می‌دهد که در نظر گرفتن رژیم‌های متفاوت برای مدل‌سازی رفتار بازده تاثیر مثبت در برازش مدل پیش‌بینی و افزایش دقت دارد. این در حالی است که مدل پیش‌بینی بدون در نظر گرفتن رژیم توان استخراج بسیار پایین تری دارد. تفاوت دقت پیش‌بینی مدل بدون رژیم و مدل‌های با در نظر گرفتن رژیم توسط آزمون‌های آماری معنی‌دار ارزیابی شد. همچنین استراتژی تدوین شده بر مبنای دقت جهت پیش‌بینی مدل‌های ارائه شده در این پژوهش بازده‌های متفاوتی را در آزمون معکوس با در نظر گرفتن هزینه‌ی معاملاتی کسب کرد. اما نکته با اهمیت این است که روش ارائه شده با در نظر گرفتن رژیم‌های رفتار بازده می‌تواند بازدهی مازاد بر بازده شاخص کسب کند. این در حالی است که استراتژی پیشنهادی حاصل از برازش مدل شبکه عصبی عمیق بدون در نظر گرفتن رژیم برای توضیح رفتار داده، بازدهی کمتر از شاخص کسب می‌کند. با توجه به گفته‌های لو و نوین بودن روش ارائه شده در این پژوهش می‌توان تا مدتی که بازار نسبت به آن تطبیق پیدا نکرده است با استفاده از این مدل بازده اضافی کسب کرد.

از نکات مهمی که این پژوهش را از سایر پژوهش‌های حوزه‌ی پیش‌بینی متمایز می‌سازد، تطابق ساختار مدل پیش‌بینی با داده‌هایی می‌باشد که از قبل ساختار آن‌ها مورد مطالعه قرار گرفته است. این در حالی هست که پژوهش‌های مشابه با بیان این که مدل‌های یادگیری عمیق توان واکاوی داده‌های بدون توزیع معین را دارند، اهمیتی به شناخت داده‌های مورد بررسی نداده‌اند [۴۴، ۱۷]. اگر چه در این پژوهش نشان دادیم که نتیجه‌ای که یک مدل یادگیری عمیق به تنهایی و بدون بازنمایی‌های رژیم رفتاری به دست می‌آورد از مدل تدوین شده بر اساس رفتار خوشه‌ای ضعیف‌تر بوده و بازده پایین‌تری کسب می‌کند. از سوی دیگر تفاوت این پژوهش با سایر پژوهش‌هایی که بر روی بازار بورس تهران انجام شده است بررسی دقت و امکان کسب بازده مازاد از بازار با استفاده از مدل تدوین شده می‌باشد. اهمیت این امر در رد یا عدم رد فرض کارایی بازار هدف می‌باشد. سایر پژوهش‌های انجام شده بر روی بورس تهران بیشتر بر روی مقایسه مدل‌ها تمرکز کرده‌اند و برتری یک مدل نسبت به دیگری لزوماً نشان دهنده‌ی امکان کسب سود مازاد با استفاده از آن‌ها نبوده است.

## ۶. پیشنهادها و محدودیت‌ها

یکی از مشکلات اساسی در مورد پژوهش‌هایی که بر روی بازار بورس تهران انجام می‌شود عدم سهولت دریافت داده‌های بازار برای مدت طولانی می‌باشد، این در حالی است که قدرت مدل‌های داده کاوی بسیار وابسته به حجم داده است. بنابراین می‌توان در چارچوب فرضیات و اهداف این پژوهش مهم‌ترین محدودیت را کافی نبودن داده‌های روزانه دانست. این در حالی است که پژوهش‌هایی که با استفاده از مدل‌های شبکه عصبی عمیق در حوزه‌ی پیش‌بینی قیمت انجام شده به سمت استفاده از داده‌های طولانی مدت رفته‌اند.

در حالی که در این پژوهش تمرکز بیشتر بر روی کارایی ضعیف شاخص بورس تهران و واکاوی روابط موجود در وقفه‌های خود بازده می‌باشد، یکی از نکات مهم، بررسی امکان ارتقاع مدل پیشنهاد شده به کمک دخیل نمودن داده‌های بازارهای موازی می‌باشد. در این راستا می‌توان به مدل پیشنهاد شده در این پژوهش متغیرهایی همچون قیمت روزانه طلا، نفت و یا ارز را اضافه نموده و امکان افزایش دقت پیش‌بینی را سنجید. همچنین می‌توان این پژوهش را بر روی داده‌های سری تالاطم پیاده سازی نموده و دقت پیش‌بینی آن را سنجید. چنین پژوهشی می‌تواند تأثیر بسزایی در افزایش بازده روش‌های بهینه سازی پرتفوی داشته باشد.

از سویی دیگر با توجه به پیشرفت روز افزون ابزارهای داده کاوی و مدل‌های پیشرفته متن کاوی، امکان کاوش در داده‌های متنی نیز فراهم شده است. این امر می‌تواند در مدل‌سازی پیش‌بینی موجب افزایش دقت شود. بدین صورت که می‌توان در شبکه‌های اجتماعی همچون توئیتر و تلگرام سوء گیری‌های رفتاری سرمایه‌گذاران و همچنین احساسات سرمایه‌گذاران را بررسی کرد. بنا بر این می‌توان قدرت پیش‌بینی مدل ارائه شده در این پژوهش را با مؤلفه‌های استخراج شده از داده‌های متنی در کنار سابقه قیمت بررسی کرد.



## منابع

1. Aminimehr, A., Raoofi, A., Aminimehr, A., & Aminimehr, A. (2020). The Role of Feature Engineering in Prediction of Tehran Stock Exchange Index Based on LSTM. *Iranian Journal of Economic Studies*, 9(2), 527-548.
2. Assadi, G., Morshedi, F. (2019). Investigating the effect of Investor Sentiment on the stock price crash risk in Tehran Stock Exchange. *Journal of Financial Management Perspective*, 9(25), 9-30(in persian)
3. Babajani, J., Taghva, M., Blue, G., & Abdollahi, M. (2019). Forecasting Stock Prices in Tehran Stock Exchange Using Recurrent Neural Network Optimized by Artificial Bee Colony Algorithm. *Financial Management Strategy*, 7(2), 195-228(in persian).
4. badieli, h., Rezazadeh, R., & Mahmoudi, H. (2017). Forecasting Stock Price Trend by Artificial Neural Networks (Case Study: Isfahan Oil Refinery Company). *FEJ*, 8(31), 167-185(in persian).
5. Bildirici, M., & Ersin, Ö. Ö. (2009). Improving forecasts of GARCH family models with the artificial neural networks: An application to the daily returns in Istanbul Stock Exchange. *Expert Systems with Applications*, 36(4), 7355-7362.
6. Bildirici, M., & Ersin, Ö. (2014). Modeling Markov Switching ARMA-GARCH Neural Networks Models and an Application to Forecasting Stock Returns. *The Scientific World Journal*, 2014, 497941.
7. Bildirici, M., & Ersin, Ö. (2016). Markov Switching Artificial Neural Networks for Modelling and Forecasting Volatility: An Application to Gold Market. *Procedia Economics and Finance*, 38, 106-121.
8. Bishop, C. (1994). Mixture density networks.
9. Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327.
10. Broock, W. A., Scheinkman, J. A., Dechert, W. D., & LeBaron, B. (1996). A test for independence based on the correlation dimension. *Econometric Reviews*, 15(3), 197-235.
11. Busse, J. A., & Clifton Green, T. (2002). Market efficiency in real time. *Journal of Financial Economics*, 65(3), 415-437.
12. Dima, B., & Miloş, L. (2009). TESTING THE EFFICIENCY MARKET HYPOTHESIS FOR THE ROMANIAN STOCK MARKET. *Annales Universitatis Apulensis Series Oeconomica*, 1, 41-41.
13. Doan, T., & Lo, A. (1988). Stock Market Prices do not Follow Random Walks: Evidence from a Simple Specification Test. *Review of Financial Studies*, 1, 41-66.
14. Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987-1007.
15. Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383-417
16. Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
17. Hajizadeh, E., Seifi, A., Fazel Zarandi, M. H., & Turksen, I. B. (2012). A hybrid modeling approach for forecasting the volatility of S&P 500 index return. *Expert Systems with Applications*, 39(1), 431-436.

18. Hamilton, J. D. (1988). Rational-expectations econometric analysis of changes in regime: An investigation of the term structure of interest rates. *Journal of Economic Dynamics and Control*, 12(2), 385-423.
19. Haofei, Z., Guoping, X., Fangting, Y., & Han, Y. (2007). A neural network model based on the multi-stage optimization approach for short-term food price forecasting in China. *Expert Systems with Applications*, 33(2), 347-356.
20. Hasannejad, M. (2018). Designing a Model for Projection of Tehran Exchange Return Employing Autoregressive Moving Average (ARMA) and Autoregressive Moving Average with External Inputs (ARMAX) Models and Assessing the Performance Thereof. *Journal of Financial Management Perspective*, 8(22), 135-158. (in persian)
21. Hekmat, Hanieh; Rahmani, Ali; Mola Nazari, Mahnaz; Mosavi, Mir Hossein; Ghalibaf Asl, Hasan (2020). Static & Dynamic Models & Stock Market Efficiency Evaluation of T.S.E. Listed Companies'. *Financial Research Journal*, 22(4), 476-495. (in Persian)
22. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
23. Kim, H. Y., & Won, C. 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
24. Kristjanpoller R, W., & Hernández P, E. (2017). Volatility of main metals forecasted by a hybrid ANN-GARCH model with regressors. *Expert Systems with Applications*, 84, 290-300.
25. Kristjanpoller, W., & Minutolo, M. (2015). Gold price volatility: A forecasting approach using the Artificial Neural Network–GARCH model. *Expert Systems with Applications*, 42.
26. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
27. Lo, A., & MacKinlay, S. (1989). Long-term memory in stock market prices.
28. Lo, A. W. (2004). The Adaptive Markets Hypothesis. *The Journal of Portfolio Management*, 30(5), 15.
29. Zolfaghari, M., Sahabi, B., & Bakhtyaran, M. j. (2020). Designing a Model for Forecasting the Stock Exchange Total Index Returns (Emphasizing on Combined Deep Learning Network Models and GARCH Family Models). *FEJ*, 11(42), 138-171. (in Persian)
30. Mohamed, A., Jawadi, F., & Nguyen, D. (2010). The Dynamics of Emerging Stock Markets: *Empirical assessments and implications*.
31. Ozbayoglu, A. M., Gudelek, M. U., & Sezer, O. B. (2020). Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, 106384.
32. Park, J.-I., Lee, D.-J., Song, C.-K., & Chun, M.-G. (2010). TAIFEX and KOSPI 200 forecasting based on two-factors high-order fuzzy time series and particle swarm optimization. *Expert Systems with Applications*, 37(2), 959-967.
33. Pele, D. T., & Voineagu, V. (2008). Testing market efficiency via decomposition of stock return. Application to Romanian Capital Market. *Journal for Economic Forecasting*, 5, 63-79.
34. Pesaran, M. H., & Timmermann, A. (1992). A Simple Nonparametric Test of Predictive Performance. *Journal of Business & Economic Statistics*, 10(4), 461-465.
35. Quandt, R. E. (1972). A New Approach to Estimating Switching Regressions. *Journal of the American Statistical Association*, 67(338), 306-310.

36. Rather, A. M., Agarwal, A., & Sastry, V. N. (2015). Recurrent neural network and a hybrid model for prediction of stock returns. *Expert Systems with Applications*, 42(6), 3234-3241.
37. Rosenberg, B., Reid, K., & Lanstein, R. (1985). Persuasive evidence of market inefficiency. *The Journal of Portfolio Management*, 11(3), 9.
38. Samuelson, P. A. (2013). Proof that Properly Anticipated Prices Fluctuate Randomly. *In the World Scientific Handbook of Futures Markets*. Volume 5, pp. 25-38. WORLD SCIENTIFIC.
39. Shiller, R. J. (1981). Do Stock Prices Move Too Much to be Justified by Subsequent Changes in Dividends? *The American Economic Review*, 71(3), 421-436.
40. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929-1958.
41. Ta, V.-D., Liu, C.-M., & Tadesse, D. A. (2020). Portfolio Optimization-Based Stock Prediction Using Long-Short Term Memory Network in Quantitative Trading. *Applied Sciences*, 10(2), 437.
42. Tehrani, r., Tajdini, s., Abbasian, E., & Mirlohi, M. (2021). Measure the level of adherence to the random walk Theory in Various Industry Indices Using Markov Switching Model. *Financial Management Strategy*, 9(1). (in Persian)
43. Vukovic, D., Vyklyuk, Y., Chernova, N., & Maiti, M. (2019). Neural network forecasting in prediction Sharpe ratio: Evidence from EU debt market. *Physica A: Statistical Mechanics and its Applications*, 542.
44. Wang, W., Li, W., Zhang, N., & Liu, K. (2020). Portfolio formation with preselection using deep learning from long-term financial data. *Expert Systems with Applications*, 143, 113042.
45. Wang, Y.-H. (2009). Nonlinear neural network forecasting model for stock index option price: Hybrid GJR-GARCH approach. *Expert Systems with Applications*, 36(1), 564-570.
46. Zhong, X., & Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1), 24.