

## بررسی عملکرد شبکه عصبی بیزین و لونبرگ مارکووات در مقایسه با مدل‌های کلاسیک در پیش‌بینی قیمت سهام شرکت‌های سرمایه‌گذاری

حسین فخاری<sup>۱</sup>، محمد ولی‌پور خطیر<sup>۲</sup>، سیده مائده موسوی<sup>۳</sup>

**چکیده:** پیش‌بینی دقیق قیمت سهام، با توجه به نوسان‌های زیاد و ریسک ذاتی بازار سرمایه، یکی از دغدغه‌های اصلی سرمایه‌گذاران و تحلیل‌گران مالی است، از این رو به کارگیری رویکردهای نوین پیش‌بینی قیمت سهام ضرورت اجتناب‌نایدیری است. بر این اساس، هدف تحقیق حاضر، مقایسه عملکرد مدل‌های پیش‌بینی شبکه عصبی با مدل‌های کلاسیک و معرفی مدل مناسب برای پیش‌بینی قیمت روز آتی سهام است. برای طراحی مدل پیش‌بینی با شبکه عصبی، از داده‌های قیمت روزانه بازار و شاخص‌های تکنیکی مالی به عنوان متغیرهای ورودی استفاده شد و برای طراحی مدل آریما، داده‌های قیمت بسته‌شدن روزانه به عنوان متغیر ورودی و همچنین قیمت بسته‌شدن روز آتی به عنوان متغیر خروجی هر دو مدل در دوره زمانی ۱۳۹۰ تا ۱۳۹۳ در نظر گرفته شد. نتایج به دست آمده با شبکه عصبی بیزین بیان کننده خطای کمتر و قدرت پیش‌بینی بیشتر آن در مقایسه با مدل آریما است. یافته‌های تحقیق گویای کارایی بیشتر شبکه عصبی بیزین در استفاده از فرآنشاهی سرمایه‌گذاری کوتاه‌مدت بازار است که می‌تواند به سرمایه‌گذاران در انتخاب پرتفوی مناسب و کسب بازده بیشتر کمک کند.

**واژه‌های کلیدی:** آریما، پیش‌بینی قیمت سهام، تابع آموزش بیزین، تابع آموزش لونبرگ، مارکووات، شبکه عصبی

۱. دانشیار گروه حسابداری، دانشکده علوم اقتصادی و اداری، دانشگاه مازندران، بالسر، ایران

۲. استادیار گروه مدیریت صنعتی، دانشکده علوم اقتصادی و اداری، دانشگاه مازندران، مازندران، ایران

۳. کارشناس ارشد حسابداری، دانشکده علوم اقتصادی و اداری، دانشگاه مازندران، مازندران، ایران

تاریخ دریافت مقاله: ۱۳۹۵/۰۵/۲۷

تاریخ پذیرش نهایی مقاله: ۱۳۹۶/۰۳/۲۷

نویسنده مسئول مقاله: محمد ولی‌پور خطیر

E-mail: m.khatir1461@gmail.com

#### مقدمه

طی چند سال اخیر، رشد و توسعه بازار سرمایه کشور و ارائه سازوکارها و ابزارهای مختلف توسط دولت برای حمایت از آن، اهمیت بازار سرمایه را در اقتصاد کشور ارتقا داده و سرمایه‌گذاری روی سهام عرضه شده در بورس اوراق بهادار را به یکی از گزینه‌های سودآور این بازار تبدیل کرده است (منجمی، ابزری و رعیتی، ۱۳۸۸). با توجه به هدف کسب سود سهامداران از بازار سرمایه، این علاقه‌مندی می‌تواند هم از سوی سرمایه‌گذاران بالقوه و بالفعل و هم دستاندرکاران بازار سرمایه از جمله تحلیل‌گران و سیاست‌گذاران بورس باشد. در این بین، مهم‌ترین چالش پیش روی سرمایه‌گذاران و تحلیل‌گران، پیش‌بینی صحیح قیمت سهام برای اخذ تصمیم‌های منطقی است. این علاقه‌مندی همراه با عدم قطعیت ذاتی محیط اطلاعاتی بازار سرمایه که از مسائل سیاسی، انتشار اطلاعات و رفتارهای متضاد بازیگران این بازارها نشت می‌گیرد، سبب می‌شود پیش‌بینی قیمت سهام در این بازارها موضوع پیچیده‌ای تلقی شود (تیکنور، ۲۰۱۳).

بررسی مطالعات اخیر نشان می‌دهد روش‌های مختلفی به منظور کاهش عدم اطمینان سرمایه‌گذاری در بازارهای مالی وجود دارد، اما هیچ‌یک به طور کامل درست و دقیق نیستند (رامنات، راک و شان، ۲۰۰۸). بنابراین در اختیار داشتن روش‌های پیش‌بینی مناسب، دقیق و با حداقل خطا در تعیین قیمت آینده سهام، برای مدیران سرمایه‌گذاری و سرمایه‌گذاران خرد و تحلیل‌گران بسیار ضروری است.

اگرچه رویکرد عمدۀ پیش‌بینی قیمت سهام، استفاده از سری‌های زمانی و مدل‌های کلاسیک است، این روش‌ها بیشتر در محیط‌هایی با تغییرات محدود قادرند با تقریب خوبی پیش‌بینی کنند و در مواردی چون پیش‌بینی بازار سهام که شرایط محیطی همواره در حال تغییر است، نمی‌توانند تغییرات محیطی را با تقریب درستی تخمین بزنند. به این ترتیب نیاز به مدل‌های نوین و سیستم‌های هوشمند برای پیش‌بینی این دوره‌ها ضروری است. برای این منظور روش‌هایی نظری شبکه‌های عصبی، منطق فازی، الگوریتم ژنتیک و سایر الگوریتم‌های فراابتکاری برای حل مسائل در حوزه‌های مختلف علوم، توسعه یافته‌اند که از این میان، استفاده از تکنیک شبکه عصبی به دلیل ماهیت غیرخطی، توان رویارویی با داده‌های متلاطم، زمان پردازش سریع و دستیابی به مدل هوشمند پیش‌بینی به منظور مدل‌سازی و پیش‌بینی، به طور فزاینده‌ای در کانون توجه قرار گرفته است (مورات و سیلان، ۲۰۰۶؛ سوزن و آرساکلیگلو، ۲۰۰۷).

با توجه به ضرورت مدل‌سازی برای پیش‌بینی تغییرات قیمت سهام، این مطالعه در صدد است به این سؤال پاسخ دهد که شبکه عصبی مصنوعی و روش رگرسیونی آریما<sup>۱</sup> تا چه اندازه قادر به

1. Autoregressive Integrated Moving Average (ARIMA)

پیش‌بینی قیمت سهام هستند و کدامیک از قدرت بیشتری برخوردارند؟ از این رو، هدف این پژوهش مقایسه عملکرد این دو روش در پیش‌بینی قیمت سهام و دستیابی به مدل مناسب برای پیش‌بینی قیمت روز آتی سهام در شرکت‌های سرمایه‌گذاری پذیرفته شده در بورس اوراق بهادار تهران است.

### پیشینه نظری پژوهش

بازار سرمایه به عنوان یکی از زیرسیستم‌های بخش مالی اقتصاد همراه با بازار پول، کارکرد بسیار مهمی در توسعه فعالیت‌های اقتصادی و ایجاد وضعیت مطلوب اقتصادی در کشورهای مختلف دارد. بازار سرمایه از بازارهای مختلفی از جمله بازار سهام، بازار مشتق شده و بازار اوراق بدهی تشکیل شده است. این بازارها محل معامله ابزارهای مالی از جمله سهام، ابزار مشتق شده و اوراق بدهی هستند (سعیدی و آقایی، ۱۳۸۸). بی‌تردید سرمایه‌گذاری و معامله هریک از این ابزارهای مالی از عوامل تأثیرگذار در توسعه بازار سرمایه است. صرف نظر از نوع و روش سرمایه‌گذاری، پیش‌بینی سرمایه‌گذار از منافع آتی حاصل از سرمایه‌گذاری، یکی از مهم‌ترین عوامل تأثیرگذار بر تصمیم‌های مالی به شمار می‌رود (گرشاسبی، ۱۳۸۹). در این رابطه، بازار سهام نیز یکی از مهم‌ترین و فعال‌ترین بازارهای مالی است و پیش‌بینی قیمت سهام در این بازار میان سرمایه‌گذاران و تحلیل‌گران حرفه‌ای، اهمیت شایان توجهی دارد (داش و داش، ۲۰۱۶). پیش‌بینی روند بازار سهام بدلیل نوسان‌های محیطی و تلاطم ذاتی روندهای روزانه بازار، بسیار پیچیده است. پیچیدگی حرکات روزانه بازار و قیمت سهام از عواملی نظیر حوادث سیاسی، اخبار بازار، گزارش‌های دوره‌ای درآمد و رفتارهای متعارض معامله نشئت می‌گیرد و پیش‌بینی قیمت روزانه سهام را بسیار دشوار می‌کند (تیکنور، ۲۰۱۳). از سوی دیگر، تعداد زیاد و ناشناخته‌بودن عوامل مؤثر بر بازار بورس، موجب عدم اطمینان در زمینه سرمایه‌گذاری شده است. بنابراین به طور طبیعی تمام تلاش سرمایه‌گذار برای کاهش عدم اطمینان است و پیش‌بینی بازار بورس یکی از ابزارهای کاهش عدم اطمینان محسوب می‌شود (اسدی و همکاران، ۲۰۱۲). بنابراین پیش‌بینی موفق قیمت سهام، منافع مالی و مزیت‌های شایان توجهی را برای سرمایه‌گذاران در پی خواهد داشت (وی، ۲۰۱۶). در این راستا، فعالان این بازار از مدل‌های مختلفی برای تحلیل داده‌های بازار برای پیش‌بینی قیمت سهام استفاده کرده‌اند (لی و همکاران، ۲۰۱۶).

در حال حاضر برای پیش‌بینی‌های مالی از روش‌های ریاضی و آمار و سری زمانی استفاده می‌شود (چن و چن، ۲۰۱۵) که پیش‌بینی سری زمانی یکی از موضوعات مهم و شایان توجه در

پیش‌بینی شاخص سهام است (وی، ۲۰۱۶). از جمله روش‌های سری زمانی می‌توان به آر<sup>۱</sup>، آرما<sup>۲</sup>، آریما<sup>۳</sup>، آرج<sup>۴</sup> و گارج<sup>۵</sup> اشاره کرد (چن و چن، ۲۰۱۵). در روش‌های نام برده، این فرض اساسی وجود دارد که با تبیین الگوی رفتاری داده‌های تاریخی می‌توان به مدل‌های با قدرت توضیح‌دهنگی بالا دست یافت (وانیدن، ۱۹۹۶؛ اسف، ۲۰۱۱). روش‌های سری زمانی سنتی ضعف‌هایی دارند که نیاز به داده‌های تاریخی وسیع، فرض بر خطی بودن روابط میان پارامترها و نرمال بودن داده‌ها، از آن جمله‌اند؛ در حالی که عوامل متعدد تأثیرگذار بر فضای پیچیده و پرتالاطم بازار سهام و روابط غیرخطی و پویا میان پارامترهای مؤثر بر شاخص سهام، لزوم به کارگیری روش‌های هوشمند را اجتناب‌ناپذیر کرده است (چن و چن، ۲۰۱۵).

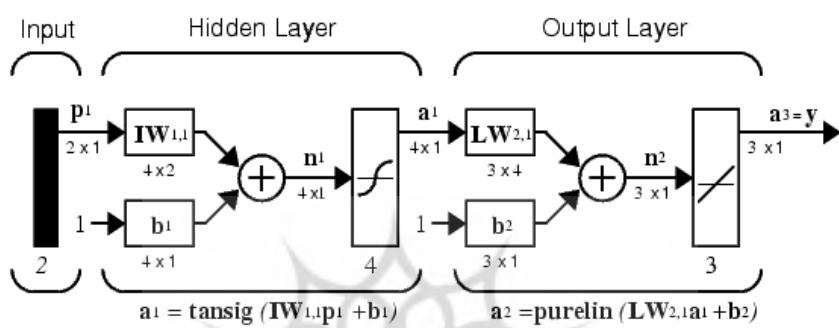
سیستم‌های هوشمند یکی از فناوری‌های نوین عصر حاضر است که با استفاده از آنها می‌توان به طراحی مدل‌هایی برای پیش‌بینی بازار سرمایه پرداخت (حنفی‌زاده و جعفری، ۱۳۸۹). مدل‌های مبتنی بر هوش مصنوعی و یادگیری ماشین بر این فرض پایه‌ریزی شده‌اند که بازارهای مالی نایستا هستند و به کارگیری مدل‌های پیچیده ریاضی در عمل مشکل است و می‌توان با نقلید از سیستم‌های عصبی بیولوژیک انسانی از طریق ماشین یادگیری به الگوهایی برای تقریب تابع پیش‌بینی دست یافت (ون‌ایدن، ۱۹۹۶؛ اسف، ۲۰۱۱).

### شبکه عصبی مصنوعی

شبکه عصبی مصنوعی ایده‌ای برای پردازش اطلاعات است که از سیستم عصبی زیستی الهام گرفته و مانند مغز به پردازش اطلاعات می‌پردازد. این سیستم، از شمار زیادی عناصر پردازشی فوق العاده به هم پیوسته به نام نورون<sup>۶</sup> تشکیل شده که برای حل یک مسئله به‌طور هماهنگ عمل می‌کنند (چستر، ۱۹۹۳). شبکه‌های عصبی، نوعی مدل‌سازی از سیستم‌های عصبی واقعی‌اند و کاربرد فراوانی برای حل مسائل در علوم مختلف دارند. حوزه‌به کارگیری این شبکه بسیار گستردۀ است؛ به گونه‌ای که در طبقه‌بندی، پیش‌بینی، تخمین، درون‌یابی، آشکارسازی و... کاربردهای متنوعی دارد (محمدعلی زاده، راعی، محمدی، ۱۳۹۴). تاکنون الگوریتم‌های متعددی برای آموزش شبکه نظیر قانون یادگیری پرسپترون، قانون یادگیری هبین، قانون یادگیری حداقل میانگین مربعات، قانون یادگیری انتشار برگشتی معرفی شده است. از میان این الگوریتم‌ها، روش

- 
1. Autoregressive (AR)
  2. Autoregressive Moving Average (ARMA)
  3. ARIMA
  4. Autoregressive Conditional Heteroscedastic (ARCH)
  5. Generalized ARCH (GARCH)
  6. Neurons

پرسپترون چندلایه پس انتشار خطا (MLP) بیشترین کاربرد را در حوزه تحقیقات مالی داشته است (آذر و کریمی، ۱۳۸۸). این شبکه‌ها در گروه شبکه‌های چندلایه پیش‌خور قرار دارند و شامل مجموعه‌ای از واحدهای حسی (نورون‌های پایه) هستند که سیگنال ورودی را در مسیر رو به جلو، به صورت لایه به لایه منتشر می‌کنند (هیکین، ۱۹۹۹). از این‌رو، در پژوهش حاضر برای طراحی مدل شبکه عصبی مصنوعی نیز، ساختار MLP مد نظر قرار گرفت.



### سری زمانی

روش دیگری که در این پژوهش استفاده می‌شود، سری زمانی تلفیقی است. یک سری زمانی مجموعه مشاهداتی است که بر اساس زمان مرتب شده و می‌تواند ایستا و پویا باشد (چن و چن، ۲۰۱۵). پویایی در سری زمانی در میانگین واریانس است؛ به این معنا که در طول زمان، میانگین واریانس مشاهدات ثابت نیست. شایان ذکر است که پویایی میانگین ناشی از روند است و پویایی واریانس از تناب داده‌ها نشئت می‌گیرد. هر سری زمانی شامل چهار مؤلفه روند، تناب، فصلی، تناب دوره‌ها و مؤلفه تصادفی پیش‌بینی‌ناپذیر است. اگر مشاهدات به‌طور پیوسته بر حسب زمان در نظر گرفته شوند، سری زمانی حاصل را پیوسته می‌نامند و اگر مشاهدات به‌طور منظم در فاصله‌های مساوی ثبت شوند سری زمانی گسسته به‌دست می‌آید (بروکول و دیویس، ۲۰۰۶).

برای مدل‌سازی سری‌های غیرفصلی ایستا، مدل‌های خودهمبسته، مدل میانگین متحرک و مدل مرکب خودهمبسته میانگین متحرک استفاده می‌شود. مدل خودهمبسته بر پایه زنجیره مارکوف در زنجیره زمانی بنا شده است. هنگامی یک سری زمانی از زنجیره مارکوف تعییت می‌کند که هر داده ثبت شده سری زمانی، در زمان  $t$  با زمان قبل یا زمان بعد از خود مرتبی باشد. در مدل میانگین متحرک، متغیر  $t$  از روی مقدار تصادفی در همان لحظه، به علاوه  $q$  برابر مقدار تصادفی مربوط به زمان‌های قبل از  $t$  برآورد می‌شود. فرایندهای خودهمبسته میانگین

متحرک که فرایندهای مرکب نامیده می‌شوند، از ترکیب دو فرایند پیشین به‌دست می‌آید (بروکول و دیویس، ۲۰۰۶).

### پیشنهاد تجربی

طی سال‌های اخیر، تحقیقات متعددی در زمینه بررسی قیمت سهام و نوسان‌های بازار سهام انجام گرفته که در آنها از تکنیک‌های مختلف سری زمانی و هوش مصنوعی استفاده شده است. نمونه‌ای از این تحقیقات به صورت خلاصه در قالب جدول ۱ بیان شده است.

جدول ۱. پژوهش‌های انجام شده در زمینه پیش‌بینی قیمت سهام

محقق / محققان (سال)	موضوع تحقیق	یافته‌ها
نمایی و کیامهر (۱۳۶۸)	پیش‌بینی بازده روزانه سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی	در این پژوهش از شبکه عصبی پرسپترون چندلایه با توابع یادگیری متفاوت استفاده شده است. بر اساس نتایج این پژوهش، رفتار سری زمانی بازده روزانه سهام شرکت‌ها فرایند تصافی نبوده و دارای حافظه است. همچنین شبکه‌های عصبی مصنوعی توانایی پیش‌بینی بازده روزانه را با میزان خطای نسبتاً مناسبی دارند.
رمضانیان، رمضان‌پور و پوربخش (۱۳۹۰)	رویکردهای جدید در پیش‌بینی با استفاده از شبکه‌های عصبی - فازی	نتایج مدل شبکه عصبی مصنوعی با نتایج پیش‌بینی روش‌های میانگین متحرک ساده، میانگین متحرک موزون، نمو هموار ساده، نمو هموار دوبل، روند خطی، روند تابع ترکیبی مقایسه شدند. نتایج حاکی از برتری روش شبکه عصبی فازی نسبت به سایر روش‌ها بود.
شمس و ناجی زواره (۱۳۹۴)	پیش‌بینی قیمت آتی سکه طلا با استفاده از مدل ترکیبی سیستم ژنتیک فازی - عصبی و مدل خطی آریما	نتیجه پیش‌بینی حاصل از مدل ترکیبی ارائه شده با نتیجه به‌دست آمده از مدل خطی آریما بر اساس معیار سنجش خطا MAPE مقایسه شد. نتایج نشان داد روش ژنتیک - عصبی پیش‌بینی مناسب‌تر از روش آریما داشته و خطای پیش‌بینی آن نیز بسیار کمتر است.
سنول و اوزارتون (۲۰۱۰)	پیش‌بینی قیمت سهام با روش شبکه عصبی مصنوعی (مطالعه موردي: ترکيه)	از شبکه عصبی و رگرسیون لجستیک برای پیش‌بینی قیمت سهام در بورس استانبول استفاده کردند. نتایج مقایسه مدل‌ها، عملکرد مطلوب‌تر شبکه عصبی را نسبت به رگرسیون لجستیک نشان می‌دهد.
مصطفی (۲۰۱۰)	پیش‌بینی حرکت تغییرات سهام با شبکه عصبی (مطالعه موردي: کویت)	هدف مقاله، پیش‌بینی رفتار قیمت بسته‌شدن (بازار بورس کویت) با استفاده از داده‌ها برای سال‌های ۲۰۰۱ تا ۲۰۰۳ بود و نتایج نشان داد مدل‌های عصبی محاسباتی، ابزارهای مفید برای پیش‌بینی حرکات بازار سهام در بازارهای در حال ظهور است.

## ادامه جدول ۱

یافته‌ها	موضوع تحقیق	محقق / محققان (سال)
این تحقیق در صدد پیش‌بینی قیمت روز آتی سهام با تکنیک‌های آریما و شبکه عصبی است. نتایج تحقیق بر بالاتر بودن کارایی آریما در پیش‌بینی قیمت سهام نسبت به شبکه عصبی دلالت دارد.	یک مدل شبکه عصبی برای پیش‌بینی سری‌های زمانی	خاشعی و بیجاری (۲۰۱۰)
بر اساس نتایج، توانایی پیش‌بینی مدل شبکه عصبی در این مطالعه برتر از مدل آریما است.	یک شبکه عصبی با الگوریتم بیزین برای پیش‌بینی قیمت سهام	تیکنور (۲۰۱۳)
در این تحقیق برای ساخت مدل پیش‌بینی ترکیبی از دو روش خطی آرما و هموارسازی نمایی و یک روش غیرخطی شبکه عصبی مصنوعی بازگشتی استفاده شده است. همچنین برای تعیین وزن مناسب در مدل ترکیبی، الگوریتم ژنتیک به کار رفته است.	شبکه عصبی مصنوعی بازگشتی <sup>۱</sup> و یک مدل هیبریدی برای پیش‌بینی بازده سهام	رانهر، آکاروال و ساستری (۲۰۱۵)
در این پژوهش به منظور مقایسه مدل‌های پیش‌بینی از دو معارف دقت و سرعت پیش‌بینی استفاده شده است. نتایج حاکی از آن است که مدل‌های ELM و Kernel و ماشین بردار پشتیبانی، بیشترین دقت و سرعت را در پیش‌بینی قیمت سهام نسبت به روش شبکه عصبی و مدل Basic ELM دیگر دارند.	پیش‌بینی بازار سهام با روش ماشین یادگیری	لی و همکاران (۲۰۱۶)

## روش‌شناسی پژوهش

تحقیق حاضر از جنبه هدف کاربردی است و از حیث روش و چگونگی جمع‌آوری داده‌ها از نوع توصیفی - مطالعه موردی به‌شمار می‌رود. از نظر موضوعی، پژوهش حاضر در قلمرو مسائل پیش‌بینی مالی قرار می‌گیرد و از نظر زمانی به‌صورت بازه‌ای بوده و سال‌های ۱۳۹۰ تا ۱۳۹۳ را دربرمی‌گیرد. جنبه مکانی پژوهش نیز، شرکت‌های عضو بورس و اوراق بهادار تهران در نظر گرفته شده است. جامعه آماری این تحقیق، شرکت‌های پذیرفته شده در بورس و اوراق بهادار تهران است که از این میان، پنج شرکت سرمایه‌گذاری ملی ایران، سپه، بهمن، آتیه دماوند، صنعت و معدن انتخاب شدند؛ زیرا ترکیب سهام آنها شامل صنایع مختلف است و با نوسان‌ها و

1. Recurrent neural network

تلاطم‌های نامنظمی همراهاند. با توجه به کاربرد گسترده و همچنین ویژگی رویکردهای کلاسیک و غیرکلاسیک، در این مطالعه دو رویکرد کلاسیک (مدل آریما) و هوش مصنوعی (شبکه عصبی) برای ایجاد یک مدل پیش‌بینی در نظر گرفته شده است. شایان ذکر این که، مهم‌ترین ویژگی مدل‌های کلاسیک، تفسیرپذیری آنها و مهم‌ترین ویژگی مدل‌های شبکه عصبی نیز رویارویی با اختشاش و تلاطم در داده‌هast است. با توجه به این که کاربران این مدل‌ها در نهایت به حداقل شدن خطای پیش‌بینی می‌اندیشند، شاخص میانگین مربعات خطأ به عنوان معیار عملکردی مدل‌ها مد نظر قرار گرفت. در مدل آریما، قیمت‌های بسته‌شدن روزانه سهام و در مدل شبکه عصبی مصنوعی نه متغیر (جدول ۲) به عنوان متغیرهای ورودی انتخاب شدند؛ همچنین قیمت بسته‌شدن روز آتی نیز به عنوان متغیر خروجی هر دو مدل در نظر گرفته شد.

جدول ۲. متغیرهای ورودی مدل شبکه عصبی

نام متغیر	توضیحات
قیمت بازگشایی	اولین قیمت معامله‌شده سهام پس از بازگشایی روزانه بازار
حداقل قیمت	کمترین قیمت معامله‌شده سهام طی زمان معامله روزانه
حداکثر قیمت	بیشترین قیمت معامله‌شده سهام طی زمان معامله روزانه
قیمت بسته‌شدن	آخرین قیمت معامله‌شده سهام طی زمان معامله روزانه
شاخص قدرت نسبی (RSI) <sup>۱</sup>	افزایش و کاهش را در قیمت پایانی برای یک دوره معین اندازه‌گیری می‌کند
ویلیامز <sup>۲</sup> R%	شاخص مومنتوم است که شرایط اشباع خرید و اشباع فروش را نشان می‌دهد و از صفر تا صد نوسان می‌کند.
استوکستیک <sup>۳</sup> K %	نوسان نمای اندازه حرکت (مومنتوم) است که موقعیت‌های اشباع خرید و اشباع فروش را تعیین می‌کند.
استوکستیک D%	نوسان نمای اندازه حرکت (مومنتوم) است که موقعیت‌های اشباع خرید و اشباع فروش را تعیین می‌کند.
میانگین‌های متحرک نمایی <sup>۴</sup> (EMA)	میانگین قیمت سهم یا شاخص در یک دوره زمانی معین است.

در ادامه، روابط مدنظر شاخص‌های RSI، K%，R%，D% و EMA معرفی شده‌اند (تیکنور، ۲۰۱۳).

1. Relative Strength Index

2. Williams

3. Stochastic

4. Exponential Moving Average

$$RSI = 100 - \frac{100}{1 + (\sum_{i=0}^{n-1} Up_{t-i} / n) / (\sum_{i=0}^{n-1} Dw_{t-i} / n)} \quad (۱)$$

$$Williams' \%R = \frac{H_n - C_r}{H_n - L_n} \times 100 \quad (۲)$$

$$Stochastic\ K\% = \frac{C_t - L_{t-n}}{HH_{t-n} - LL_{t-n}} \times 100 \quad (۳)$$

$$Stochastic\ D\% = \frac{\sum_{i=0}^{n-1} K_{t-i}\%}{N} \quad (۴)$$

$$EMA(h)_t = EMA(h)_{t-1} + \alpha \times (C_t - EMA(h)_{t-1}) \quad (۵)$$

در رابطه‌های بالا،  $C_t$  قیمت بسته شدن امروز؛  $L_t$  پایین‌ترین قیمت امروز؛  $L_{t-1}$  پایین‌ترین قیمت یک روز قبل؛  $H_t$  بالاترین قیمت در زمان  $t$ ؛  $LL_t$  پایین‌ترین  $L_t$  در روزهای  $t$  قبل؛  $HH_t$  بالاترین  $H_t$  در روزهای  $t$  قبل؛  $Up_t$  تغییرات صعودی قیمت امروز نسبت به روز قبل؛  $Dw_t$  تغییرات نزولی قیمت امروز نسبت به روز قبل و  $H$  دوره زمانی برای میانگین متحرک  $h$  روز است.

در ادامه، اطلاعات مربوط به این متغیرها برای پنج شرکت یاد شده در بازه زمانی ۱۳۹۰/۰۷/۱ تا ۱۳۹۳/۰۷/۱ از پایگاه داده بورس اوراق بهادار تهران جمع آوری شد؛ سپس مجموعه داده‌ها به دو گروه آموزش و آزمایش (آزمون) دسته‌بندی شدند. در این روش، ۲۰ درصد از مجموعه کل داده‌ها برای آزمون نهایی کارآمدی مدل کنار گذاشته شده و از ۸۰ درصد باقی برای آموزش و دستیابی به مدل مناسب پیش‌بینی قیمت سهام شرکت‌های سرمایه‌گذاری استفاده می‌شود. به این ترتیب با استفاده از روش‌های آریما و شبکه عصبی بیزین، مدل پیش‌بینی قیمت سهام به دست آمد و کارآمدی پیش‌بینی هر یک از این مدل‌ها از طریق محاسبه میزان دقیقت آنها در پیش‌بینی قیمت سهام در داده‌های آزمایش محاسبه شد. بهمنظور ارزیابی نتایج مدل شبکه عصبی و مقایسه آن با مدل آریما، از معیار میانگین مربعات خطأ استفاده شد (رابطه ۶).

$$MSE = \frac{1}{N} \sum_{i=1}^N (ei)^2 \quad (۶)$$

### یافته‌های پژوهش

شبکه‌های استفاده شده در این پژوهش، شبکه عصبی پرسپترون چند لایه<sup>۱</sup> با الگوریتم آموزشی بیزین<sup>۲</sup> است. شبکه عصبی پرسپترون نوعی شبکه پیشرو چندلایه، شامل یک ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. با وجود فرمول‌های مختلف، بهترین روش برای تعیین تعداد نرون‌های لایه پنهان روش آزمون و خطاست. بنابراین در این تحقیق، در شبکه‌های دولایه، تمام حالت‌های دو نuron تا ۱۰ نuron با تابع آستانه سیگموئیدی<sup>۳</sup> برای لایه اول و یک نuron با تابع آستانه پیورلین<sup>۴</sup> برای لایه خروجی به کمک برنامه‌نویسی انجام شده، تحت آموزش قرار گرفت. همچنین برای شبکه‌های سه لایه نیز تمام حالت‌های دو نuron تا ۱۰ نuron با تابع آستانه سیگموئیدی برای لایه اول و دوم و یک نuron با تابع آستانه پیورلین برای لایه خروجی آموزش داده شد و الگوریتم‌های بیزین و لونبرگ مارکووات نیز به عنوان توابع آموزش به کار گرفته شدند. به منظور فراهم‌شدن فرصت آموزش بهتر برای هر یک از حالت‌های شبکه، برای هر یک از شبکه‌ها ۱۰ بار فرصت آموزش در مطلب برنامه‌نویسی شده است. به این ترتیب برای شبکه‌های دولایه، ۹۰ بار و برای شبکه‌های سه لایه نیز ۸۱۰ بار فرصت آموزش فراهم شد. بنابراین ۹۰۰ بار آموزش در مدل‌های مختلف انجام گرفت و با توجه به دو نوع تابع آموزشی که در این تحقیق به کار رفته است، در مجموع ۱۸۰۰ بار آموزش به کمک نرم‌افزار متلب برنامه‌نویسی شد و به اجرا درآمد. این فرایند برای هر یک از شرکت‌های سرمایه‌گذاری به طور جداگانه انجام گرفت که در ادامه نتایج آن ارائه می‌شود.

برای ارزیابی عملکرد شبکه‌هایی که آموزش دیده‌اند، از معیار دقت پیش‌بینی MSE به منظور انتخاب ساختار مناسب شبکه از نظر تعداد لایه و تعداد نuron‌ها و ارزیابی یادگیری شبکه‌های عصبی و حصول بهترین نتایج استفاده شد.

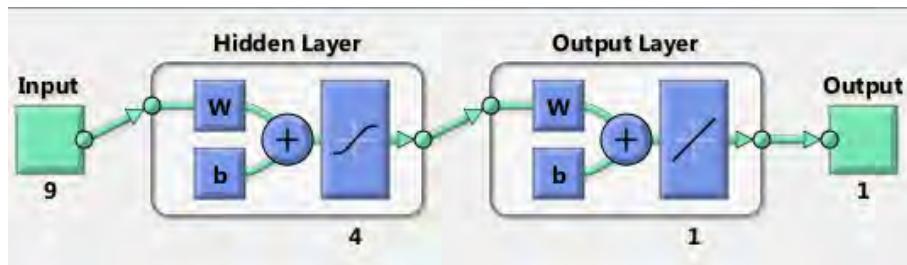
شکل ۲ ساختار شبکه دولایه را با ۹ متغیر ورودی و یک متغیر خروجی نشان می‌دهد که تابع نuron لایه اول (پنهان) به صورت تابع سیگموئید و نuron لایه خروجی به صورت تابع پیورلین است. نتیجه آزمون تمام شبکه‌های دو نuron تا ۱۰ نuron برای لایه پنهان با ۱۰ بار تلاش مجدد نشان داد، بهترین تعداد نuron لایه پنهان برای شبکه دولایه هم با الگوریتم آموزش لونبرگ مارکووات و هم با الگوریتم آموزش بیزین برای پیش‌بینی قیمت سهام شرکت سرمایه‌گذاری ملی، چهار نuron است.

1. Multi-layer perceptron (MLP)

2. Bayesian

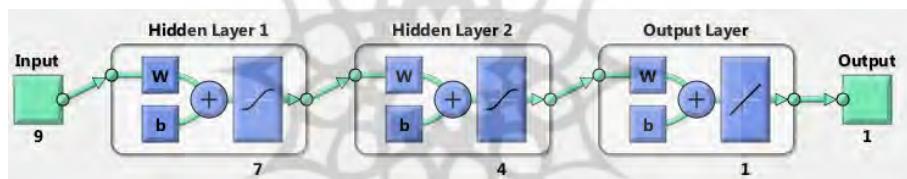
3. Sigmoid

4. Purelin



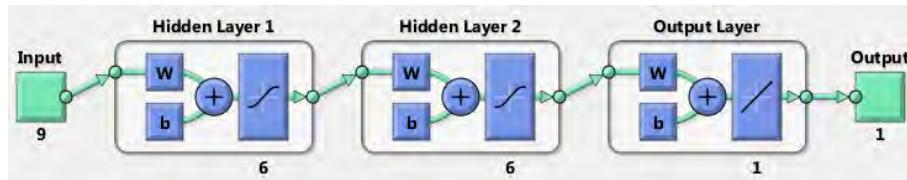
شکل ۲. ساختار بهینه شبکه دو لایه - شرکت سرمایه‌گذاری ملی

شکل ۳ نیز، ساختار شبکه سه لایه را با ۹ متغیر ورودی و یک متغیر خروجی نشان می‌دهد که تابع نورون لایه اول و لایه دوم (پنهان) به صورت تابع سیگموئید و نورون لایه خروجی به صورت تابع پیورلین است. نتیجه آزمون تمام شبکه‌های دو نورون تا ۱۰ نورون برای لایه‌های پنهان با ۱۰ بار تلاش مجدد نشان داد، بهترین تعداد نورون لایه پنهان برای شبکه سه لایه با تابع الگوریتم آموزش لونبرگ مارکوات برای پیش‌بینی قیمت سهام شرکت سرمایه‌گذاری ملی، به صورت زیر است.



شکل ۳. ساختار بهینه شبکه سه لایه با الگوریتم آموزش لونبرگ - شرکت سرمایه‌گذاری ملی

شکل ۴ ساختار شبکه سه لایه را با ۹ متغیر ورودی و یک متغیر خروجی نشان می‌دهد که تابع نورون لایه اول و لایه دوم (پنهان) به صورت تابع سیگموئید و نورون لایه خروجی به صورت تابع پیورلین است. نتیجه آزمون تمام شبکه‌های دو نورون تا ۱۰ نورون برای لایه‌های پنهان با ۱۰ بار تلاش مجدد نشان داد، بهترین تعداد نورون لایه پنهان برای شبکه سه لایه با تابع الگوریتم آموزش بیزین برای پیش‌بینی قیمت سهام شرکت سرمایه‌گذاری ملی، به صورت زیر است.



شکل ۴. ساختار بهینه شبکه سه لایه با الگوریتم آموزش بیزین - شرکت سرمایه‌گذاری ملی

جدول ۳ وضعیت بهینه شبکه عصبی دولایه و سهلایه را برای پیش‌بینی قیمت روزانه سهام شرکت‌های سرمایه‌گذاری مورد مطالعه با توجه به هر یک از توابع آموزش لونبرگ مارکوات و بیزین نشان می‌دهد.

جدول ۳. بهترین نتایج عملکردی مدل شبکه عصبی

MSE	تعداد نورون				تابع آموزش	شرکت سرمایه‌گذاری	
	لایه خروجی	لایه دوم	لایه اول	تعداد لایه			
۵۱۹/۹	۱	-	۴	دو لا يه	لونبرگ مارکوات	ملی	
۳۵۶/۴	۱	۴	۷	سه لا يه			
۲۳۷/۶	۱	-	۴	دو لا يه			
۲۵۷/۶	۱	۶	۶	سه لا يه			
۷۷/۴۳	۱	-	۲	دو لا يه	لونبرگ مارکوات	بهمن	
۸۳/۹۴	۱	۲	۳	سه لا يه			
۶۶/۹۵	۱	-	۵	دو لا يه	بیزین		
۴۸/۴۸	۱	۴	۷	سه لا يه			
۵۱۹/۶	۱	-	۴	دو لا يه	لونبرگ مارکوات	آئیه دماوند	
۹۸۵۴/۱	۱	۷	۳	سه لا يه			
۲۷۳/۶	۱	-	۴	دو لا يه	بیزین		
۱۷۳۸/۷	۱	۴	۶	سه لا يه			
۱۳۸۳/۱	۱	-	۵	دو لا يه	لونبرگ مارکوات	صنعت و معدن	
۱۲۵۹/۸	۱	۷	۶	سه لا يه			
۹۳۶/۶۹	۱	-	۴	دو لا يه	بیزین		
۸۰/۹	۱	۶	۵	سه لا يه			
۱۰۷/۳	۱	-	۴	دو لا يه	لونبرگ مارکوات	سپه	
۱۰۳۵/۸	۱	۲	۵	سه لا يه			
۶۱۶/۶	۱	-	۶	دو لا يه	بیزین		
۵۷۳/۹	۱	۶	۶	سه لا يه			

نتایج بدست آمده از مدل‌های مختلف شبکه عصبی نشان می‌دهد برای تمام شرکت‌های سرمایه‌گذاری، شبکه‌هایی که با توابع آموزش بیزین آموزش دیده‌اند، MSE کمتر و در نتیجه عملکرد بهتری داشته‌اند.

### مدل آریما (p,d,q)

عبارت‌های  $p$ ,  $d$  و  $q$  به ترتیب تعداد جملات خودرگرسیون، مرتبه تفاضل گیری و تعداد جملات میانگین متحرک‌اند. برای پیش‌بینی بهوسیله آریما، لازم است ایستایی متغیر قیمت پایانی سهام

که یک سری زمانی است، بررسی شده و مرتبه  $d$  تعیین شود. در صورتی که  $d$  برابر با صفر شود، فرایند آریما تبدیل به آرما می‌شود. برای تعیین میزان  $d$  باید از آزمون ریشه واحد دیکی - فولر روی داده‌های باقی‌مانده مدل‌های آرما که برآورد شده‌اند، استفاده کرد (بروکول و دیویس، ۲۰۰۶).

### تخمین مدل AR(1)

با توجه به مقدار  $P$ -value کمتر از ۵ درصد در جدول ۴، ضرایب مدل خودگرسیونی مرتبه اول (AR(1)) معنادار است. البته، آماره‌های ضریب تعیین و دوربین واتسون نیز در رابطه با میزان تبیین‌کنندگی واریانس توسط مدل مد نظر و همچنین میزان همخطی در مدل اهمیت دارند که مقدار مطلوب برای این دو آماره بهتری ۱ و ۲ است؛ به این معنا که هر چه مقدار آماره ضریب تعیین به ۱ و آماره دوربین واتسون به ۲ نزدیک‌تر باشد، مدل بهتری برآش شده است. شایان ذکر است که مهم‌ترین معیار در ارزیابی و مقایسه دقت مدل‌های مختلف سری زمانی برآش شده، آماره آکاییک و شوارتز است که پس از برآش مدل‌های مختلف از این آماره برای مقایسه استفاده می‌شود. همچنین مقدار ضریب تعیین ۰/۹۹۸ و آماره دوربین واتسون ۱/۳۵ به‌دست آمده که در سطح خطای ۱۰ درصد نیز نمی‌توان فرض وجود همخطی را رد کرد.

جدول ۴. خروجی آزمون مدل AR(1) – شرکت سرمایه‌گذاری ملی

Prob	t-Student	Std. Error	Coefficient	variable
۰/۵۷۷	-۰/۵۵۷	۷۷۳۹/۷۴۳	۴۰۳۳/۱۴۲	C
۰/۰۰۰	۸۱۱/۳۴۵	-۰/۰۰۱۲	-۰/۹۹۹	AR(1)
۱۲۰۳/۱۳۷	Mean dependent var		-۰/۹۹۸	R-squqre
۶۹۹/۰۵۷۸	S.D dependent var		-۰/۹۹۸	Adjusted R-square
۹/۱۲۶۴	Akaike info criterian		۲۳/۱۷۱	S.E of regression
۹/۱۳۹۰	Schwartz criterian		۳۸۸۱۶۳/۸	Sum squared resid
۹/۱۳۱۲	Hannan-Quinn criter		-۳۳۰۶/۳۲۲	Log likelihood
۱/۳۵۵	Durbin-Watson stat		۶۵۸۲۸۰/۹	F-statistic
			-۰/۰۰۰	Prob(F-statistic)

### تخمین مدل MA(1)

با توجه به مقدار  $P$ -value کمتر از صفر در جدول ۵، ضرایب مدل میانگین متحرک مرتبه اول (MA(1)) معنادار است. همچنین مقدار ضریب تعیین ۰/۷۳۸ و آماره دوربین واتسون ۰/۰۷۸ به‌دست آمده که در سطح خطای ۱۰ درصد نیز نمی‌توان فرض وجود همخطی را رد کرد.

جدول ۵. خروجی آزمون مدل (1) – شرکت سرمایه‌گذاری ملی

Prob	t-Student	Std. Error	Coefficient	variable
./.000	۴۵/۹۰۱	۲۶/۲۰۹۳۹	۱۲۰۳/۰۳۷	C
./.000	۱۱۴/۸۴۴	./.۰۰۸۵	.۰/۹۷۶۷	MA(1)
۱۲۰۲/۴۵۹	Mean dependent var	./.۷۳۸	R-squre	
۶۹۸/۸۱۳۹	S.D dependent var	./.۷۳۸	Adjusted R-square	
۱۴/۵۹۷	Akaike info criterian	۳۵۷/۲۶۸	S.E of regression	
۱۴/۶۱۰	Schwartze criterian	۹۲۴۱۱۷۱۲	Sum squared resid	
۱۴/۶۰۲	Hannan-Quinn criter	-۵۲۹۶/۹۲۹	Log likelihood	
./.۰۷۸۳	Durbin-Watson stat	۲۰۴۹/۷۸۴	F-statistic	
		./.000	Prob(F-statistic)	

### تخمین مدل آریما (1,۰,۱)

با توجه به جدول ۶ که مقدار P-value کمتر از صفر به دست آمده، ضرایب مدل خودگرسیون مرتبه اول و میانگین متحرک مرتبه اول معنادار است. در این مدل تفاضل صفر ( $d = 0$ ) فرض شده است. به بیان دیگر، این مدل در صورتی معنادار است که داده‌های سری مدنظر ایستا باشند و در واقع فرضیه وجود ریشه واحد رد شود، در غیر این صورت باید از سری تفاضل‌گیری مرتبه یک گرفت و ایستایی آن را بررسی کرد. در این مدل، مقدار ضریب تعیین ۰/۹۹۹ و آماره دوربین واتسون ۱/۹۳۳ است که در سطح خطای ۱۰ درصد فرضیه وجود همخطی رد می‌شود.

جدول ۶. خروجی آزمون مدل (1,۰,۱) آریما – شرکت سرمایه‌گذاری ملی

Prob	t-Student	Std. Error	Coefficient	variable
.۰/۴۲۸	./.۷۹۲	۳۸۱۳/۴۳۰	۳۰۲۰/۳۶۲	C
./.000	۶۶۰/۸۵۸	./.۰۰۱۵	.۰/۹۹۹	AR(1)
./.000	۸/۰۱۵	./.۰۳۵	./.۲۸۵	MA(1)
۱۲۰۳/۱۳۷	Mean dependent var	./.۹۹۹	R-squre	
۶۹۹/۰۵۷۸	S.D dependent var	./.۹۹۹	Adjusted R-square	
۹/۰۳۴۱	Akaike info criterian	۲۲/۱۱۰	S.E of regression	
۹/۰۵۳۱	Schwartze criterian	۳۵۲۹۷۵/۱	Sum squared resid	
۹/۰۴۱۴	Hannan-Quinn criter	-۳۳۷۱/۸۷۴	Log likelihood	
۱/۹۳۷	Durbin-Watson stat	۳۶۱۴۸۸/۴	F-statistic	
		./.000	Prob(F-statistic)	

جدول ۷ نتایج بررسی مدل‌های مختلف سری زمانی را برای شرکت‌های سرمایه‌گذاری مدنظر در این تحقیق نشان می‌دهد.

جدول ۷. نتیجه بررسی مدل‌های سری زمانی در شرکت‌های سرمایه‌گذاری

MSE	نیزه‌گیری	آزاده نمودار	آزاده کاکا	آزاده ویسون	فکری	مدل سری زمانی	شرکت سرمایه‌گذاری
۵۲۹	-	۹/۱۳۹	۹/۱۲۶	۱/۳۵۵	.۰/۹۹	AR(1)	ملی
۱۲۶۷۳۶	-	۱۴/۶۱	۱۴/۵۹	.۰/۰۷	.۰/۷۳	MA(1)	
۴۸۴	-۱۶/۵۳	۹/۰۵	۹/۰۳	۱/۹۳	.۰/۹۹	ARIMA(۱,۰,۱)*	
۱۰۰	-	۷/۵۵	۷/۵۴	۱/۱۴۷	.۰/۹۹	AR(1)	بهمن
۶۰۰۲۵	-	۱۳/۸۵	۱۳/۸۴	.۰/۰۴	.۰/۷۴	MA(1)	
۸۱	-۱۵/۳۹	۷/۳۹	۷/۳۷	۱/۸۸	.۰/۹۹	ARIMA(۱,۰,۱)*	
۱۰۶۰۹	-	۱۲/۱۳	۱۲/۱۲	۱/۵۰	.۰/۹۹	AR(1)	آتبیه دماوند
۱۰۶۰۹	-	۱۶/۶۷	۱۶/۶۶	.۰/۱	.۰/۷۳	MA(1)	
۱۰۰۰۰	-۲۶/۴۱	۱۲/۰۸	۱۲/۰۷	۱/۹۶	.۰/۹۹	ARIMA(۱,۰,۱)*	
۱۴۴۴	-	۱۰/۱۵	۱۰/۱۴	۱/۶۴	.۰/۹۹	AR(1)	صنعت و معدن
۱۶۸۱۰۰	-	۱۴/۸۸	۱۴/۸۷	.۰/۰۹	.۰/۷۳	MA(1)	
۱۳۶۹	-۲۶/۹۵	۱۰/۱۲	۱۰/۱	۲	.۰/۹۹	ARIMA(۱,۰,۱)*	
۱۰۲۴	-	۹/۸	۹/۷۹	۱/۵۵	.۰/۹۹	AR(1)	سپه
۱۵۰۵۴۴	-	۱۴/۶۷	۱۴/۶۵	.۰/۱	.۰/۷۳	MA(1)	
۹۶۱	-۲۶/۷۳	۹/۷۶	۹/۷۴	۱/۹۹	.۰/۹۹	ARIMA(۱,۰,۱)*	

### نتیجه‌گیری و پیشنهادها

پیش‌بینی آینده در عرصه پویای اقتصادی و بازار سرمایه، به یکی از مهم‌ترین مباحث علوم مالی تبدیل شده است. اهمیت این موضوع از آنجا نشئت می‌گیرد که پیش‌بینی دقیق قیمت سهام در بازارهای سرمایه، مهم‌ترین معیار موفقیت در زمینه تصمیم‌های سرمایه‌گذاری، قیمت‌گذاری اوراق بهادر و مدیریت ریسک است. از این رو سرمایه‌گذاران و فعالان بازار سهام به دنبال یافتن روش‌های مناسب و کارا بهمنظور تجزیه و تحلیل قیمت روزانه سهام و تصمیم‌گیری در خصوص سرمایه‌گذاری جدید یا خاتمه فعالیت‌های سرمایه‌گذاری فعلی خود هستند.

با این که روش‌های کلاسیک مانند الگوهای سری‌های زمانی، رویکرد غالب پیش‌بینی سهام محسوب می‌شوند و در زمینه پیش‌بینی متغیرهای مختلف توفیق نسبی داشته‌اند، نتایج آنها نتوانسته است پژوهشگران این عرصه را راضی کند. از این رو برخی از مزیت‌های شبکه عصبی مصنوعی در امر پیش‌بینی، سبب توجه بیشتر محققان و فعالان بازار به این رویکرد شده است. در این رابطه، تحقیق حاضر به پیش‌بینی قیمت سهام شرکت‌های سرمایه‌گذاری ملی، بهمن، صنعت و معدن، سپه و آتیه دماوند با استفاده از شبکه عصبی مصنوعی و مقایسه این تکنیک با روش رگرسیونی آریما به منظور تعیین مدل مناسب پیش‌بینی قیمت روز آتی پرداخته است که در آن از شبکه پرسپترون چندلایه و توابع آموزشی لونبرگ مارکووات و بیزین استفاده شده است.

بر اساس نتایج این تحقیق، بهترین ساختار شبکه عصبی طراحی شده به منظور پیش‌بینی قیمت روز آتی سهام برای تمام شرکت‌های سرمایه‌گذاری، شبکه سه‌لایه است. البته تعداد نورون‌های شبکه‌های یاد شده برای هر یک از شرکت‌های سرمایه‌گذاری متفاوت در نظر گرفته شد. نورون‌های لایه اول و دوم از نوع تابع سیگموئیدی و نورون لایه خروجی از نوع تابع خطی (پیورلین) بودند. مقایسه عملکرد شبکه عصبی با توابع آموزش لونبرگ و بیزین نشان داد عملکرد شبکه عصبی با تابع آموزش بیزین برای تمام شرکت‌های سرمایه‌گذاری بهتر از عملکرد شبکه با تابع لونبرگ است. همچنین بررسی مدل‌های مختلف سری زمانی نیز نشان داد، بهترین مدل سری زمانی برای تمام شرکت‌های سرمایه‌گذاری، مدل (۱۰,۱) آریما است.

در جدول ۸ معیار عملکرد MSE هر یک از مدل‌های شبکه عصبی و آریما برای پنج شرکت سرمایه‌گذاری به تفکیک نشان داده شده است.

جدول ۸. نتایج مقایسه شبکه عصبی و مدل آریما

آریما	شبکه عصبی	MSE	
		شرکت سرمایه‌گذاری	
۴۸۴	۲۵۷/۶	ملی	
۸۱	۴۸/۴۸	بهمن	
۱۰۰۰۰	۱۷۳۸/۷	آتیه دماوند	
۱۳۶۹	۸۰۹	صنعت و معدن	
۹۶۱	۵۷۳/۹	سپه	

با توجه به قابلیت شبکه عصبی در مدل‌سازی رفتار پدیده مورد بررسی، می‌توان پیشنهاد کرد سرمایه‌گذاران و فعالان در بازار بورس، این مدل پیش‌بینی قیمت سهام را در قالب یک سیستم

پشتیبانی تصمیم برای ارزیابی نوسان‌های قیمت سهام در طول یک بازه زمانی به کار گیرند، چرا که با توجه به قابلیت یادگیری مدل‌های مبتنی بر هوش مصنوعی، با گذر زمان و کسب تجربه‌های جدید، توانایی و قابلیت سیستم در پیش‌بینی دقیق قیمت سهام افزایش خواهد یافت و این موجب کاهش ریسک سرمایه‌گذاران در این بخش و همچنین تصمیم‌گیری درست در مورد وضعیت آینده سرمایه‌گذاری خواهد شد. پیشنهاد می‌شود در تحقیقات آتی، عملکرد مدل‌های غیرپارامتریک و همچنین سایر مدل‌های هوش مصنوعی، نظریه استنتاج فازی عصبی و الگوریتم‌های فرآباتکاری بررسی شود.

## فهرست منابع

- آذر، ع؛ کریمی، س. (۱۳۸۹). پیش‌بینی بازده سهام با استفاده از نسبت‌های حسابداری با رویکرد شبکه‌های عصبی. *فصلنامه تحقیقات مالی*، ۱۱(۲۸)، ۲۰-۳.
- رمضانیان، م. ر؛ رمضان‌پور، ا؛ پوربخش، س. ح. (۱۳۹۰). رویکردهای جدید در پیش‌بینی با استفاده از شبکه‌های عصبی - فازی: قیمت نفت. *پژوهش‌های مدیریت در ایران*، ۱۵(۳)، ۱۶۸-۱۴۹.
- حنفی‌زاده، پ؛ جعفری، ا. (۱۳۸۹). مدل ترکیبی شبکه‌های عصبی مصنوعی پیش‌خور و خودسازمانده کوهوون برای پیش‌بینی قیمت سهام. *مطالعات مدیریت صنعتی*، ۸(۱۹)، ۱۸۷-۱۶۵.
- شمس، ش؛ ناجی زواره، م. (۱۳۹۴). بررسی مقایسه‌ای بین مدل ترکیبی سیستم ژنتیک فازی - عصبی خودسازمانده و مدل خطی در پیش‌بینی قیمت توافقی قراردادهای آتی سکه طلا. *فصلنامه تحقیقات مالی*، ۱۷(۲)، ۲۳۹-۲۵۸.
- گرشاسبی، ع. (۱۳۸۹). بررسی مقایسه‌ای عوامل پیش‌بینی‌کننده بازده سهام در بورس اوراق بهادار تهران و بورس اوراق بهادار نیویورک با رویکرد شبکه عصبی و رگرسیون خطی. *پایان‌نامه کارشناسی ارشد*. دانشگاه مازندران.
- محمد علی‌زاده، آ؛ راعی، ر؛ محمدی، ش. (۱۳۹۴). پیش‌بینی سقوط بازار سهام با استفاده از شبکه‌های عصبی نگاشت خود سازمانده. *فصلنامه علمی - پژوهشی تحقیقات مالی*، ۱۷(۱)، ۱۷۸-۱۵۹.
- نمایی، م؛ کیامهر، م. م. (۱۳۸۷). پیش‌بینی بازده روزانه سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی. *تحقیقات مالی*، ۳(۹)، ۱۳۴-۱۱۵.
- Asadi, S., Hadavandi, E., Mehmanpazir, F. & Nakhostin, M. M. (2012). Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction. *Knowledge-Based Systems*, 35, 245-258.

- Assaf, N. A. (2011). *Mercado financeiro*. (10th ed.). So Paulo: Editora Atlas.
- Azar, A. & Karimi, S. (2010). Neural Network Forecasts of Stock Return Using Accounting Ratios. *Journal of financial research*, 11(28), 3-20. (in Persian)
- Brockwell, P. J., & Davis, R. A. (2016). Introduction to time series and forecasting. Springer.
- Chen, M. Y. & Chen, B. T. (2015). A hybrid fuzzy time series model based on granular computing for stock price forecasting. *Information Sciences*, 294, 227-241.
- Chester, M. (1993). *Neural networks: a tutorial*. Prentice-Hall, Inc.
- Dash, R. & Dash, P. (2016). Efficient stock price prediction using a Self Evolving Recurrent Neuro-Fuzzy Inference System optimized through a Modified technique. *Expert Systems with Applications*, 52, 75-90.
- Garshasbi, A. (2010). A comparative study of stock returns predictors in Tehran Stock Exchange and New York Stock Exchange using neural network approach and linear regression. *Master Thesis, University of Mazandaran*. (in Persian)
- Hanafizade, P. & Jafari, A. (2010). The hybrid model of feed forward and kohonen's self organizing artificial neural networks in predicting the stock price. *Journal of Industrial Management Studies*, 8(19), 165-187. (in Persian)
- Hykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Printice-Hall, Inc., New Jersey.
- Khashei, M. & Bijari, M. (2010). An artificial neural network model for timeseries forecasting. *Expert Systems with Applications*, 37(1), 479-489.
- Li, X., Xie, H., Wang, R., Cai, Y., Cao, J., Wang, F. ...., & Deng, X. (2016). Empirical analysis: stock market prediction via extreme learning machine. *Neural Computing and Applications*, 27(1), 67-78.
- Mohammad Alizadeh, A., Raie, R., Mohammadi, Sh. (2016). Prediction of stock market crash using self-organizing maps. *Journal of financial research*, 17(1), 159-178. (in Persian)
- Monadjemi, S. A., Abzari, M. & Rayati Shavazi, A. (2009). Modeling of stock price forecasting in stock exchange market using fuzzy neural networks and genetic algorithms. *Journal of Quantitative Economics*, 6(22), 1-26.

- Mostafa, M. M. (2010). Forecasting stock exchange movements using neural networks: Empirical evidence from Kuwait. *Expert Systems with Applications*, 37(9), 6302-6309.
- Murat, Y. S. & Ceylan, H. (2006). Use of artificial neural networks for transport energy demand modeling. *Energy Policy*, 34(17), 3165-3172.
- Namazi, M. & Kiamehr, M. M. (2008). Predicting Daily Stock Returns of Companies listed in Tehran Stock Exchange Using Artificial Neural Networks. *Journal of financial research*, 9(3), 115-134. (in Persian)
- Patel, J., Shah, S., Thakkar, P. & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert Systems with Applications*, 42(1), 259-268.
- Ramezanian, M. R., Ramezanpour, E., & Pourbakhsh, S. H. (2011). New Approaches in Forecasting Using Neuro-Fuzzy Networks (Case Study: The Crude Oil Price). *Journal of management research in Iran*, 15(3), 149-168. (in Persian)
- Ramnath, S., Rock, S. & Shane, P. (2008). The financial analyst forecasting literature: A taxonomy with suggestions for further research. *International Journal of Forecasting*, 24(1), 34-75.
- 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.
- Saeidi, A. & Aghaei, A. (2009). Predicting Financial Distress of firms Listed in Tehran Stock Exchange Using Bayesian networks. *Journal of Accounting And Auditing Review*, 16 (56), 59-78.
- Şenol, D. & Özturan, M. (2010). Stock Price Direction Prediction Using Artificial Neural Network Approach: The Case of Turkey. *Journal of artificial Intelligence*, 3, 261-268.
- Shams, Sh., NajiZavareh, M. (2016). Comparison between the Hybrid Model of Genetic Fuzzy and Self Organizing Systems and Linear Model to Predict the Price of Gold Coin Futures Contracts. *Journal of financial research*, 17(2), 239-258. (in Persian)
- Sözen, A. & Arcaklıoglu, E. (2007). Prospects for future projections of the basic energy sources in Turkey. *Energy Sources*, Part B, 2(2), 183-201.

- Ticknor, J. L. (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications*, 40(14), 5501-5506.
- Van Eyden, R. J. (1996). The Application of Neural Networks in the Forecasting of Share Prices (Finance and Technology Publishing, Haymarket, VA).
- Wei, L. Y. (2016). A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting. *Applied Soft Computing*, 42, 368-376.

