

ارزیابی مدل‌های شبکه عصبی مصنوعی ایستا و پویا در پیش‌بینی قیمت سهام

علی اکبر نیکواقبال^۱

نادیا گندلی علیخانی^۲

اسماعیل نادری^۳

تاریخ پذیرش: ۹۲/۷/۲۰

تاریخ دریافت: ۹۲/۶/۲

چکیده

پیش‌بینی آینده در عرصه پویای اقتصاد و بازارهای مالی از جمله بازار بورس به یکی از مهمترین مسائل در علوم مالی ارتقاء یافته است. همچنین، در دهه‌ی اخیر مدل‌های شبکه عصبی به علت عملکرد واقع بینانه‌تر این مدل‌ها مورد توجه محققین قرار گرفته و از انواع مختلف آنها برای پیش‌بینی استفاده شده است. اکنون این سؤال مطرح است که، کدام یک از این مدل‌ها قدرت بالاتری برای تبیین فرآیندهای آتی بورس را دارا می‌باشد؟ در همین راستا، این مطالعه به مقایسه دقت عملکرد مدل‌های شبکه عصبی ایستا و پویا در پیش‌بینی (تک متغیره^۱) بازدهی شاخص قیمت و بازده نقدی بورس تهران می‌پردازد تا امکان انتخاب الگوی بهینه برای پیش‌بینی متغیر مذکور را میسر نماید. داده‌های مورد استفاده در این پژوهش به صورت روزانه و شامل بازه‌ی زمانی پنجم فروردین ۱۳۸۸ تا سی‌ام آبان ۱۳۹۰ می‌باشد. همچنین الگوهای مورد استفاده در این پژوهش عبارتند از: دو مدل ایستای؛ شبکه‌ی عصبی فازی (ANFIS) و شبکه عصبی چند لایه پیشخور (MFNN) و نیز یک مدل شبکه‌ی عصبی پویای اتورگرسیو (NNARX) هستند. این پژوهش عملکرد مدل‌های مذکور را، بر اساس معیارهای محاسبه‌ی خطای پیش‌بینی میانگین مجذور خطا (MSE)^۲ و نیز معیار جذر میانگین مجذور خطا (RMSE)^۳ مورد ارزیابی قرار داده است.

واژه‌های کلیدی: پیش‌بینی، بازار بورس، مدل ANFIS، مدل ANN و مدل NNAR.

۱- دانشیار دانشکده اقتصاد دانشگاه تهران، Nikueghbal@yahoo.com

۲- کارشناس ارشد اقتصاد دانشگاه آزاد اسلامی واحد علوم و تحقیقات خوزستان، N.alikhani@khouzestan.srbiau.ac.ir

۳- کارشناس ارشد اقتصاد دانشگاه تهران، (مسئول مکاتبات) Naderi.ec@ut.ac.ir

۱- مقدمه

پیش‌بینی آینده در عرصه پویای اقتصاد و بازار سرمایه به یکی از مهمترین مسائل مورد بحث در علوم مالی ارتقاء یافته است. مسائل اقتصادی و تجاری به شدت تحت تأثیر مسائل اجتماعی، سیاسی و فرهنگی هستند و بسیاری از پارامترهای آنها ناشناخته بوده و با روش‌های کمی به سختی قابل اندازه‌گیری می‌باشند. از سوی دیگر، عواملی چون «اقتصاد اطلاعات^۱» و شکل‌گیری اطلاعات نامتقارن در بازارهای مالی و به دنبال آن پیچیدگی‌های ناشی از تحلیل اثرات انواع متغیرها بر شاخص بورس، موجبات دوچندان گشتن اهمیت دقت و کارایی مقوله پیش‌بینی را فراهم آورده است. در حقیقت مدل‌های اقتصادی را می‌توان از طریق بررسی میزان دقت پیش‌بینی مورد آزمون قرار داد. بدین صورت که اگر یک مدل اقتصادی در تبیین روابط موجود بین متغیرها موفق باشد، باید بتواند پیش‌بینی صحیحی از آینده متغیرها نیز ارائه نماید. لذا در چند دهه اخیر، تحقیقات در زمینه مدل‌ها و تکنیک‌های پیش‌بینی، اهمیت و شتاب بیشتری پیدا نموده است. در این میان، روش‌های کلاسیک مانند الگوهای رگرسیونی و ساختاری، اگرچه توفیقات نسبی در زمینه پیش‌بینی متغیرهای مختلف داشته‌اند، اما نتایج آن نتوانسته است پژوهشگران این عرصه را راضی نماید، چرا که عموماً این روش‌ها به اطلاعات به دست آمده از رویدادهای تاریخی متکی می‌باشند. از آنجا که عمدتاً مسائل مالی و اقتصادی موجب شکل‌گیری روابط غیرخطی و پیچیده در بازار سهام می‌شوند، لذا استفاده از مدل‌های غیرخطی و انعطاف‌پذیر (همانند مدل‌های شبکه عصبی) در مدل‌سازی و

پیش‌بینی شاخص این بازارها، می‌تواند نتایج قابل توجهی را در بر داشته باشد. این پژوهش در نظر دارد مدل‌های مختلف شبکه عصبی مصنوعی را در پیش‌بینی بازدهی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران با استفاده از داده‌های سری‌زمانی روزانه طی دوره ۱۳۸۸/۱/۵ الی ۱۳۹۰/۷/۳۰ (۶۱۶ مشاهده) بوده، که از ۵۵۶ مشاهده (تقریباً معادل ۹۰٪ مشاهدات) برای انجام تخمین‌ها و از ۶۰ مشاهده برای انجام پیش‌بینی خارج از نمونه بررسی و ارزیابی نماید.

۲- مبانی نظری و مروری بر پیشینه پژوهش

با توجه به رشد و اهمیت روزافزون بازارهای مالی، وجود هرگونه تغییراتی در این بازارها، آثار شگرفی بر اقتصاد می‌گذارد. از سوی دیگر، تغییرات حوادث اقتصادی، اجتماعی، فرهنگی و نیز سیاسی بر این بازارها اثر گذاشته، و موجبات سردرگمی شدید سرمایه‌گذاران و ایجاد نااطمینانی عملکرد بازارهای مذکور و در نتیجه کاهش اعتماد عمومی سرمایه‌گذاران به این بازارها را در پی داشته باشد. به این ترتیب، طی دو دهه اخیر پیش‌بینی دقیق تغییرات قیمت دارایی‌های مالی توجه پژوهشگران و سیاست‌گذاران را به خود جلب نموده است، تا شرایط مطلوب تخصیص بهینه منابع مالی و ارزیابی عملکرد مدیریت ریسک فراهم آورند.

۱-۲- بررسی کارایی بازار بورس

نخستین گام در انجام پیش‌بینی یک سری از داده‌ها، بررسی قابلیت پیش‌بینی‌پذیری آن می‌باشد. از این‌رو بررسی این نکته که "آیا در بازار بورس اوراق بهادار تهران، «فرضیه بازار کارآمد» صادق می‌باشد؟"

و یا به بیان دیگر، "آیا نوسانات قیمت و بازدهی سهام با استفاده از اطلاعات در دسترس و عمومی قابل پیش‌بینی می‌باشد؟"، از اهمیت ویژه‌ای برخوردار است.

ناتوانی در برای پیش‌بینی قیمت سهام به دلیل عوامل متعدد تأثیر گزار بر آن سبب ارایه «فرضیه کارایی بازار» شد^۵ (گرنجر و تیمرن، ۲۰۰۴). بر اساس فرضیه بازار کارا قیمت‌ها در بازار سهام از فرآیند گام تصادفی پیروی می‌کنند، به این مفهوم که در چنین بازاری، بازده سهام را نمی‌توان بر اساس تغییرات گذشته قیمت‌ها پیش‌بینی نمود، زیرا اطلاعات به سرعت در بازار منتشر شده و بر قیمت سهام تأثیر خواهد گذاشت (تهرانی و همکاران، ۱۳۸۷). فرضیه بازار کارا در شکل تکامل یافته‌تر خود بیانگر آن است که اگر بازده قابل پیش‌بینی بود، بسیاری از سرمایه‌گذاران سودهای نامحدود کسب کرده و در اینصورت یک "ماشین چاپ پول" ایجاد شده که ثروت نامحدودی را تولید می‌نمود، که این امر، در یک اقتصاد پایدار ممکن نیست (گرنجر و تیمرن، ۲۰۰۴).

تاکنون تحقیقات زیادی در خصوص کارایی بورس اوراق بهادار تهران صورت پذیرفته که، بیشتر این تحقیقات به شواهدی دال بر ناکارایی بورس اوراق بهادار تهران دست یافته‌اند. لازم به ذکر است که، اگرچه در برخی از مطالعات وجود کارایی ضعیف در بازار بورس اوراق بهادار تأیید شده است (مانند مطالعه سلیمی‌فر و شیرزور، ۱۳۸۹) ولی، علت داشتن ظاهری تصادفی (کارایی ضعیف) در شاخص‌های سهام را، می‌توان در اینکه سری مورد نظر از یک فرآیند غیرخطی معین تبعیت کنند، جست‌وجو کرد. بنابراین در چنین شرایطی این شاخص‌ها ناکارا بوده و به همین دلیل نمی‌توان با

آزمون‌های خطی بین این ویژگی و الگوی گام تصادفی تمایزی قائل شد (مشیری و مروت، ۱۳۸۴). در صورتی که، بیشتر مطالعات که با روش‌های پیچیده و غیرخطی به بررسی وجود کارایی در بازار بورس اوراق بهادار تهران پرداخته‌اند، به وجود ناکارایی در بازار بورس اوراق بهادار تهران اذعان داشته‌اند (مانند مطالعه‌ی راسخی و خانعلی‌پور، ۱۳۸۸ و مطالعه‌ی تهرانی و همکاران، ۱۳۸۷ و مطالعه‌ی مشیری و مروت، ۱۳۸۴ و فروتن، ۱۳۸۳). رد فرضیه کارایی بازار سهام، مهر تأییدی بر قابلیت پیش‌بینی‌پذیری سری بازدهی سهام، به کمک مدل‌های غیرخطی خواهد داشت. در بخش بعدی به تبیین مدل‌های سری‌زمانی غیرخطی می‌پردازیم.

۲-۲- مدل‌های شبکه عصبی

هوش مصنوعی با وجود نوپا بودن، با استقبال قابل توجه پژوهشگران و محققین مواجه بوده است. انواع شبکه‌های عصبی مصنوعی مختلف، به نوعی مغز را الگو قرار داده و سعی دارند تا از طریق تقلید از ذهن انسان (فرآیند یادگیری)^۶ با استفاده از روش‌های محاسباتی برای خودکارسازی فرآیند اکتساب دانش از نمونه‌ها یا داده‌ها، مسائل پیچیده و بزرگ را حل نمایند. شبکه‌های عصبی مصنوعی دارای کاربردهای متفاوتی از قبیل طبقه‌بندی داده‌ها^۷، تقریب توابع^۸، پیش‌بینی متغیرها^۹، خوشه بندی^{۱۱} و بهینه‌سازی^{۱۲} می‌باشند.

مدل‌های شبکه عصبی یک فرآیند توزیع موازی با ماهیت طبیعی بوده و مهمترین ویژگی آن توانایی مدل‌سازی روابط غیرخطی و پیچیده بدون نیاز به فرضیات قبلی از ماهیت ارتباط بین داده‌ها می‌باشد.

مدل‌های شبکه عصبی پویا (که عبارت است از مدل NNAR) و مدل‌های شبکه عصبی ایستا (شامل مدل-های ANFIS و MFNN). که در ذیل به تبیین توضیح مختصری درباره آنها خواهیم پرداخت.

۲-۲-۱- مدل‌های شبکه عصبی ایستا

با عنایت به اینکه در این مطالعه دو مدل از مدل-های شبکه عصبی ایستا (که عبارتند از مدل شبکه عصبی چند لایه پیشخور، مدل شبکه عصبی فازی) مورد استفاده قرار گرفته است، در ادامه به طور مجزا به تشریح آنها می‌پردازیم.

الف) شبکه عصبی چند لایه پیشخور

ساده‌ترین شکل شبکه عصبی تنها دو لایه دارد، لایه ورودی^{۱۹} و لایه خروجی^{۲۰}. این شبکه ها، همچون یک سیستم ورودی-خروجی عمل می‌کنند و ارزش نرون‌های ورودی را با استفاده از یک تابع تبدیل یا فعال‌ساز، برای محاسبه ارزش نرون‌های خروجی مورد استفاده قرار می‌دهند. در شبکه های عصبی چند لایه، علاوه بر لایه های ورودی و خروجی، از لایه‌های پنهان نیز استفاده می‌گردد، چرا که این لایه‌های پنهان توانایی موجب بهبود عملکرد این شبکه‌ها می‌گردند. ابتدا رامل‌هارت^{۲۱} ۱۹۸۶ و پس از آن بسیاری از نویسندگان از جمله نیلسون^{۲۲} (۱۹۸۷)، سایینکو^{۲۳} (۱۹۸۹)، فانهاشی^{۲۴} (۱۹۸۹)، هارنیک^{۲۵} (۱۹۹۰) و وایت^{۲۶} (۱۹۹۲) ثابت کرده‌اند که شبکه‌های عصبی پیشخور با یک لایه پنهان و تابع فعال ساز لوجستیک در لایه پنهان و تابع فعال ساز خطی در نرون خروجی و تعداد نرون های کافی در لایه پنهان قادرند، هر تابعی را با دقت دلخواه تقریب بزنند (نادری، ۱۳۹۱).

شبکه‌های عصبی شامل دو دسته‌ی شبکه‌های پویا و ایستا می‌باشند. شبکه‌های ایستا مانند شبکه عصبی -مصنوعی (ANN)^{۱۳} عامل پسخور^{۱۴} نداشته و در نتیجه شامل موارد تاخیری نمی‌شوند و خروجی در آنها بصورت مستقیم بوسیله ورودی‌هایی که ارتباط پیشخور^{۱۵} دارند، محاسبه می‌شود. اما در شبکه‌های عصبی پویا مانند مدل شبکه عصبی-خودرگرسیون با متغیرهای برونزا (NNAR)، خروجی به مقادیر جاری و گذشته ورودی‌ها، خروجی‌ها و نیز ساختار شبکه بستگی دارد.

۲-۲-۱- مزایای مدل‌های شبکه عصبی

از جمله مهمترین مزایای استفاده از شبکه‌های عصبی مصنوعی این است که، اولاً تشابه زیادی با سیستم عصبی انسان (هوشمند بودن) داشته و بر خلاف روش‌های مبتنی بر مدل‌های سنتی، شبکه‌های عصبی روش‌های خود تطبیقی هستند که از داده‌ها استخراج می‌شوند (قابلیت تعلیم دارند)^{۱۶}، و در آن پیش فرض‌های بسیار کمی در ارتباط با مدل‌های مورد استفاده برای مسائل وجود دارد و یا به عبارتی مدل آزاد^{۱۷} می‌باشد. ثانیاً شبکه‌های عصبی علاوه بر اینکه سرعت بالایی در پردازش اطلاعات دارند (به علت پردازش موازی)، قابلیت تعمیم‌دهی بسیار بالایی نیز، دارند. ثالثاً شبکه‌های عصبی تقریب زنده‌های کلی تابعی^{۱۸} می‌باشند. چرا که، شبکه‌های عصبی در مقایسه با روش‌های آماری سنتی، اشکال تابعی جامع‌تر و انعطاف پذیری بیشتری دارند.

۲-۲-۲- انواع مدل‌های شبکه عصبی مصنوعی

در این مطالعه دو دسته مدل‌های شبکه عصبی مورد استفاده قرار گرفته شده است، که عبارتند از:

ب) شبکه عصبی فازی

۲-۲-۲-۲-۲ مدل‌های شبکه عصبی پویا

بطور کلی شبکه‌های عصبی پویا در محیط‌های مختلفی، از جمله پیش‌بینی بازارهای مالی، سیستم‌های مکاتبه، سیستم‌های قدرت، طبقه‌بندی، عیب‌یابی، تشخیص صدا و حتی ژنتیک کاربرد فراوان دارند. یکی از پرکاربردترین رهیافت‌های مدل شبکه‌های عصبی پویا، مدل NNARX می‌باشد. این مدل، از اضافه کردن یک فرآیند AR به یک مدل شبکه عصبی حاصل خواهد شد. شبکه عصبی پویا (NNARX)، دارای یک بخش خطی و یک بخش غیرخطی می‌باشد، که بخش غیرخطی آن بوسیله‌ی شبکه عصبی مصنوعی پیشخور (Feed Forward) با یک لایه میانی تخمین زده می‌شود و بخش خطی آن، شامل یک مدل خودرگرسیون (AR) می‌باشد. فرم کلی مدل‌های شبکه عصبی NNAR به قرار زیر است:

(۱)

$$\hat{Y}(t) = f[u(t), u(t-1), u(t-2), \dots, u(t-n_u), y(t-1), y(t-2), \dots, y(t-n_y)]$$

که در آن f یک نگاشت انجام گرفته بوسیله شبکه عصبی می‌باشد. ورودی‌های شبکه عصبی شامل دو بخش وقفه‌های ورودی (سیگنال‌های ورودی) برونزا $u(t)$ و وقفه‌های مقادیر هدفی^{۳۳} (وقفه‌های سیگنال‌های خروجی) $y(t)$ می‌باشند. اعداد n_u و n_y به ترتیب وقفه‌های ورودی برونزا و مقادیر واقعی هدف بوده، که بوسیله سیستم شبکه عصبی تعیین می‌گردند. گفتنی است که، تابع آموزش این شبکه لونبرگ-مارکوات (LM^{۳۳}) بوده، که در این نوع تابع آموزش، مقادیر وزن‌ها و اریب‌ها^{۳۴} بر اساس روش LM بهینه‌سازی به هنگام می‌شوند.

استدلال یا منطق فازی یک روش قوی حل مسأله با کاربردهای وسیع در کنترل صنعتی و پردازش اطلاعات است. این روش راه ساده‌ای را برای بیرون کشیدن نتایج معین از اطلاعات ضعیف، نامعین و مبهم فراهم می‌آورد. روش فازی شبیه تصمیم‌گیرهای بشری همراه با قابلیت آن برای کار کردن با داده‌های تقریبی و پیدا کردن راه‌حل‌های صریح می‌باشد. نظریه مجموعه فازی اولین بار در سال ۱۹۶۵ توسط یک استاد ایرانی به نام لطفی عسگری زاده (معروف به لطفی زاده) و استاد دانشگاه برکلی آمریکا، مطرح شد^{۳۷}. نظریه مجموعه‌های فازی روش مناسبی را برای تحلیل سیستم‌های پیچیده و فرآیندهای تصمیم‌گیری ایجاد می‌کند هنگامی که الگوی عدم قطعیت، به‌خاطر تغییرپذیری ذاتی یا مبهم بودن فراتر از تصادفی بودن، وجود دارد. برخلاف منطق کلاسیک که نیاز به فهم عمیق از یک سیستم، سئوالات دقیق و مقادیر عددی صریح دارد، منطق فازی، این اجازه را به ما می‌دهد، که به مدل‌سازی سیستم‌های پیچیده با سطح بالایی از خلاصه‌سازی ناشی از تجربه و دانش ما، پردازیم (وانوس و همکاران^{۳۸}، ۲۰۰۰).

به طور کلی منطق فازی دارای سه مرحله مشخص کلی است که عبارتند از: ۱- مرحله فازی سازی^{۲۹}: داده‌های عددی را در حوزه دنیای واقعی به اعداد فازی در حوزه فازی تبدیل می‌کند. ۲- مرحله تجمیع^{۳۰}: محاسبه مقادیر فازی (همه بین صفر و یک) در حوزه فازی در این مرحله صورت می‌گیرد. ۳- مرحله عکس فازی سازی^{۳۱}: تبدیل معکوس اعداد فازی بدست آمده در حوزه فازی به داده‌های عددی در حوزه دنیای واقعی آخرین مرحله است.

همچنین، تابع فعال‌سازی پیش فرض برای این نوع شبکه عصبی، تابع تانژانت هیپربولیک می‌باشد.

مزیت استفاده از این مدل، قابلیت پیش‌بینی‌های بلندمدت دقیق‌تر، در شرایط یکسان، نسبت به مدل ANN می‌باشد. نحوه‌ی آموزش در این نوع شبکه‌ها، مبتنی بر قانون یادگیری تصحیح خطا بوده، که با استفاده از مجموعه وزن‌های تصادفی اولیه، فرآیند آموزش را آغاز می‌کند. و پس از تعیین خروجی مدل برای هر یک از الگوهای ارائه شده در مجموعه‌ی آموزش، خطای حاصل از تفاوت بین خروجی مدل و مقادیر مورد انتظار محاسبه گشته و با بازگشت به درون شبکه در برای عکس (خروجی به ورودی)، تصحیح می‌شود (فهیمی فرد و همکاران، ۱۳۸۸).

اصولاً پیش‌بینی شاخص بازدهی سهام به علت تأثیرپذیری شدید آنها از بسیاری از عوامل اقتصادی و غیراقتصادی، در زمره‌ی پیچیده‌ترین موارد برای پیش‌بینی قرار دارد. به همین سبب، در تحقیقات اخیر سعی شده است تا با بکارگیری مدل‌های پیچیده‌تر، موجبات افزایش دقت، صحت و کارایی این مدل‌ها را فراهم آورند.

ملین و همکاران^{۳۵} (۲۰۱۲)، گورسن و همکاران^{۳۶} (۲۰۱۱)، سونی^{۳۷} (۲۰۱۱)، دیس و پاوار^{۳۸} پاوار^{۳۸} (۲۰۱۰)، جیندو^{۳۹} (۲۰۱۰)، لی و لیو^{۴۰} (۲۰۰۹)، پریتام^{۴۱} (۲۰۰۸)، سنموژی^{۴۲} (۲۰۰۶) با استفاده از مدل شبکه عصبی مصنوعی به پیش‌بینی بازار سهام در مناطق مختلف جهان پرداخته‌اند. همچنین سوهیب‌نجارد و پرمکایسواد^{۴۳} (۲۰۱۰)، مهرآرا و همکاران^{۴۴} (۲۰۱۰)، تانگ سنگ^{۴۵} (۲۰۰۷) و گئورگسکو و دینوکا (۲۰۰۵) علاوه بر مدل MFNN از مدل‌های^{۴۶} BPNN،^{۴۷} GMDH^{۴۸}، NNARX و ANFIS^{۴۹} در زمینه پیش‌بینی

قیمت‌ها در بازار سهام استفاده کرده‌اند. تمامی تحقیقات به این نتیجه دست یافتند که مدل‌های مختلف شبکه عصبی دقت پیش‌بینی بسیار بالایی دارند.

از جمله مقالات داخلی نیز می‌توان به مقاله‌ی حیدری‌زارع و کردلوئی (۱۳۸۹) با بکارگیری متغیرهای اثرگذار بر شاخص قیمت سهام مانند نرخ ارز (شامل نرخ دلار آمریکا و نرخ یورو)، قیمت طلا و قیمت نفت نیز به عنوان متغیرهای برونزا استفاده نمودند. فهیمی فرد و همکاران (۱۳۸۹) نیز با استفاده از شبکه عصبی رویکرد فازی (ANFIS)^{۵۰} و ARIMA به پیش‌بینی قیمت خرده فروشی محصولات کشاورزی پرداخته‌اند. همچنین، بافنده-ایمان دوست و همکاران (۱۳۸۸) به پیش‌بینی نرخ ارز با استفاده از مدل‌های عصبی- فازی ANFIS، شبکه عصبی خودرگرسیون NNARX و خودرگرسیونی ARIMA پرداخته‌اند. نتایج این تحقیق بیانگر کارایی بالاتر مدل‌های شبکه عصبی نسبت به مدل‌های سری‌زمانی و خودرگرسیونی بوده است. فلاح‌شمس و دلنوازاصغری (۱۳۸۸) در مقاله- ای به مقایسه‌ی مدل‌های شبکه عصبی پیش‌خور^{۵۱} و مدل‌های ARIMA پرداختند. آذر و افسر (۱۳۸۵) نیز با استفاده از شبکه عصبی رویکرد فازی به پیش‌بینی قیمت سهام پرداخته‌اند.

۳- نتایج پژوهش

در این پژوهش، مقایسه‌ی عملکرد مدل‌های شبکه عصبی ایستا و پویا در پیش‌بینی بازدهی شاخص قیمت و بازده نقدی (TEDPIX^{۵۲}) در بورس اوراق بهادار تهران بررسی می‌گردد. به همین منظور، علائم اختصاری متغیرهای بکاربرده شده در

این مقاله عبارتند از: TEDPIX؛ بیانگر شاخص قیمت و بازده نقدی، dltd؛ سری بازدهی بورس اوراق بهادار تهران. بر این اساس، پیش از هرچیز به بررسی پیش‌بینی‌پذیری شاخص مذکور به کمک آزمون‌های نسبت واریانس و آزمون BDS می‌پردازیم.

۳-۱- بررسی پیش‌بینی‌پذیری سری بازدهی بورس
در این بخش برای تجزیه و تحلیل علل استفاده از مدل‌های شبکه عصبی به عنوان دسته‌ای از مدل‌های غیرخطی، به بررسی دو نکته خواهیم پرداخت. نخست، بررسی غیرتصادفی بودن (و بالتبع پیش‌بینی‌پذیری) سری بازدهی بورس به کمک آزمون نسبت واریانس و دیگر، بررسی غیرخطی بودن آن بر پایه آزمون BDS.

الف- آزمون نسبت واریانس (VR)

این آزمون بر مبنای آزمون «لو و مکینلی»^{۵۳} بوده و برای بررسی اینکه آیا رفتار اجزاء سری بازدهی بورس «مارتینگلی»^{۵۴} می‌باشد، استفاده می‌شود. در این آزمون، با رد فرضیه صفر، می‌توان نتیجه گرفت که، سری آزمون شده i.i.d نخواهد بود (بلی^{۵۵}، ۲۰۱۱). این در حالی است که بطور کلی رد فرضیه صفر آزمون VR، بیانگر وجود اثراتی اعم از خطی و یا غیرخطی میان پسماندهای یا خود متغیر سری زمانی مورد بررسی، می‌باشد (الخزایی و همکاران^{۵۶}، ۲۰۱۱).

جدول (۱): نتایج آزمون نسبت واریانس در سری

بازدهی بورس

Value	d.f	Probability	معیار آزمون
۶/۳۸	۷۵۶	۰/۰۰۰	Variance ratio test

منبع: یافته‌های تحقیق

نتایج آزمون فوق بیانگر آن است که، هیچگونه شواهدی دال بر اینکه سری مذکور (و نیز سری وقفه‌های آن) از نوع فرآیندهای مارتینگلی باشند، وجود نداشته و در نتیجه، فرآیند تولید داده در آنها تصادفی نمی‌باشد. به همین دلیل می‌توان به پیش‌بینی‌پذیر بودن این سری پی برد. نکته قابل توجه اینکه، از نتایج این آزمون نمی‌توان پی به خطی و یا غیرخطی بودن فرآیند تولید داده در سری بازدهی بورس پی برد، بلکه تنها می‌توان مارتینگلی نبودن و برخورداری از قابلیت پیش‌بینی‌پذیری آن را نتیجه گرفت.

ب- آزمون BDS

این آزمون که توسط بروک، دکرت و شینکمن (BDS) در سال ۱۹۸۷م معرفی گردید، بر مبنای انتگرال همبستگی که تصادفی بودن فرآیند ایجادکننده یک سری زمانی را در مقابل وجود همبستگی کلی در آن را ارزیابی می‌کند، عمل می‌نماید. روش BDS، برای انجام این منظور ابتدا سری زمانی مورد بررسی را با بکارگیری روشهای متفاوت تخمین زده و سپس از انتگرال همبستگی^{۵۷} برای آزمون فرضیه صفر مبتنی بر وجود روابط خطی میان جملات پسماند بهره می‌جوید. بنابراین رد فرضیه صفر بیانگر وجود روابط غیرخطی میان جملات پسماند سری زمانی مذکور خواهد بود (بریتکا^{۵۸}، ۲۰۰۶). آماره‌ی این آزمون (انتگرال همبستگی)، احتمال اینکه فاصله‌ی دو نقطه از مسیرهای مختلف در فضای فازی کمتر از ϵ باشد را اندازه می‌گیرد و مانند بُعد فرکتالی در فضای فازی با افزایش ϵ ، این احتمال نیز مطابق با آن تغییر می‌کند (آلمدو^{۵۹}، ۲۰۱۱).

بر همین اساس فرم کلی آزمون BDS به صورت

$$BDS_{m,T}(\varepsilon) = \frac{T^{\frac{1}{2}}[C_{m,T}(\varepsilon) - C_{1,T}(\varepsilon)^m]}{\sigma_{m,T}(\varepsilon)}$$

می باشد، که در این معادله، $\sigma_{m,T}(\varepsilon)$ تخمینی از توزیع استاندارد مجانبی $C_{m,T}(\varepsilon) - C_{1,T}(\varepsilon)^m$ می باشد و در صورتی که یک فرآیند (i.i.d) باشد، آماره BDS توزیع نرمال استاندارد مجانبی خواهد داشت. در این معادله اگر آماره BDS به اندازه کافی بزرگ باشد فرضیه صفر رد شده و فرض مقابل، مبنی بر وجود روابط غیرخطی در فرآیند مورد بررسی، پذیرفته خواهد شد (مانلی و راقاوندرا، ۲۰۱۱). این آزمون به خوبی برای ارزیابی وجود یک فرآیند غیرخطی در سری زمانی مشاهده شده قرار می گیرد. نتایج این آزمون نیز در جدول ۲ ارائه شده است.

با توجه به نتایج مندرج در جدول فوق، فرضیه صفر این آزمون، که به معنای عدم تصادفی بودن سری پسماندهای مدل مذکور می باشد، رد می شود. بنابراین، می توان به وجود یک فرآیند غیرخطی (که می تواند دارای یک فرآیند آشوب گونه نیز باشد) در سری بازدهی بورس پی برد. لازم به ذکر است که هرگاه در نتایج آزمون BDS، تصادفی بودن یک سری در بعدهای بیش از دو رد شود، احتمال

غیرخطی بودن آن سری زیاد خواهد بود (زیرا فرضیه مقابل در این آزمون نامشخص است). لذا، این آزمون شاهدهی بر غیرخطی بودن سری بازدهی بورس می باشد. بنابراین، می توان با تأیید پیش بینی پذیر بودن و نیز غیرخطی بودن سری مذکور در دوره تحقیق، از مدل های غیرخطی شبکه عصبی برای مدل سازی و پیش بینی آن استفاده نمود.

لذا، با تأیید پیش بینی پذیری و غیرخطی بودن سری مورد بررسی، در ادامه به مدل سازی و پیش بینی شاخص بازدهی بورس بر اساس مدل های شبکه عصبی بکارگرفته شده در این مطالعه خواهیم پرداخت.

۳-۲- برآورد مدل های ایستا

۳-۲-۱- برآورد مدل MFNN

با توجه به اهمیت معماری شبکه، در این قسمت پیش از مقایسه ی انواع مختلف مدل های شبکه ی عصبی پیشخور، نکات مربوط به معماری شبکه بیان می گردد. نخست اینکه برای پیدا نمودن میزان نرون بهینه سعی شده تا به کمک کد نویسی در نرم افزار MATLAB، شبکه های مختلفی را با نرون های متفاوت مورد ارزیابی قرار دهیم.

جدول (۲): نتایج آزمون BDS در سری بازدهی بورس

Dimension	BDS-Statistic	SD	Z-Statistic	Prob
۲	۰/۰۳۶۷۸۴	۰/۰۰۳۱۲۰	۱۱/۷۸۸	۰/۰۰۰۰
۳	۰/۰۵۹۵۷۰	۰/۰۰۴۹۵۴	۱۲/۰۲۵	۰/۰۰۰۰
۴	۰/۰۷۰۷۰۷	۰/۰۰۵۸۹۳	۱۱/۹۹۹	۰/۰۰۰۰
۵	۰/۰۷۲۰۱۴	۰/۰۰۶۱۳۶	۱۱/۷۳۷	۰/۰۰۰۰

منبع: یافته های تحقیق

۳-۲-۲- برآورد مدل ANFIS

روش مدل‌سازی مورد استفاده در ANFIS مشابه با سایر تکنیک‌های تشخیص سیستم می‌باشد. در مرحله اول یک سیستم پارامتری به عنوان فرض در نظر گرفته شده و سپس داده‌های ورودی و خروجی در فرم قابل استفاده در ANFIS جمع‌آوری می‌شوند. سپس می‌توان از این مدل برای آموزش مدل FIS استفاده نمود. عموماً این نوع مدل‌سازی در صورتی عملکرد خوبی دارد که داده‌های اعمال شده به ANFIS در راستای آموزش پارامترهای تابع عضویت، دربرگیرنده‌ی همه‌ی ویژگی‌های مدل FIS مورد نظر باشد.

یادگیری عصبی - انطباقی (ANFIS)^{۶۳} دارای عملکردی مشابه با شبکه‌های عصبی می‌باشد. با توجه به سه مرحله فازی‌سازی سیستم، ابتدا داده‌های ورودی را فازی‌سازی (نرمالیزه) نموده^{۶۴}، سپس داده‌های فازی شده را به داخل جعبه ابزار گرافیکی ANFIS فراخوانی کرده و FIS موجود در جعبه ابزار ANFIS را معرفی می‌نماییم، و بر مبنای جعبه ابزار FIS که در جعبه ابزار گرافیکی ANFIS به صورت انتخاب گزینه‌هایی درآمده است، (که دارای ۸ نوع تابع مختلف می‌باشد)^{۶۵} بهترین تابع را انتخاب نموده‌ایم. چرا که FIS در حقیقت فضای ورودی داده‌ها را به صورت فازی، شبکه‌بندی می‌کند لذا نوع تابع FIS برای فازی‌سازی فضای ورودی بسیار مهم می‌باشد.

از این‌رو، تعداد ۲ الی ۲۰ نرون در شبکه‌های دو و سه لایه مورد مورد ارزیابی قرار گرفت که هر کدام ۳۰ بار آموزش (Train) شده و برای مقایسه عملکرد (Performance) آنها، خطای داده‌های تست (Test) را که ۳۰٪ از کل داده‌ها را به خود اختصاص می‌دهند (به صورت زردوم)، را در مدل‌های مختلف ملاک قرار داده‌ایم. در نهایت تعداد نرون بهینه برابر ۸ نرون بوده و تعداد لایه بهینه برابر ۲ لایه بوده است. نکته دیگر اینکه، انتخاب الگوریتم آموزش بوده که از میان الگوریتم‌های مختلف بهترین عملکرد از آن الگوریتم^{۶۱} Traincgp بوده است.

نکته دیگری که می‌توان پس از اتمام طراحی شبکه بدان اشاره نمود، استفاده از ۵ وقفه از متغیر وابسته و نیز یک متغیر مجازی^{۶۲} (که معیار انتخاب آن شوک‌های نامتعارفی است که بر سری مورد بررسی وارد شده است، بدین صورت که شوک‌های بزرگتر از سه انحراف معیار وارده بر سری به عنوان شوک نامتعارف در نظر گرفته شده است) می‌باشد، که به عنوان متغیرهای ورودی مدل در نظر گرفته شده‌اند. بر پایه این ساختار، به پیش‌بینی متغیر مذکور پرداخته شده است که نتایج آن در جدول زیر ارائه شده است. همانطور که ملاحظه می‌شود، نتایج مدل فوق که با در نظر گرفتن متغیرهای مجازی، از عملکرد بهتری به لحاظ برخورداری از خطای پیش‌بینی کمتر، می‌باشند.

جدول (۳): نتایج تخمین انواع مدل‌های MFNN

ردیف	مدل	MSE	RMSE
۱	MFNN (5lag of dltd)	۰/۰۰۰۰۲۶۳	۰/۰۰۵۱۳
۲	MFNN (5lag of dltd & DUM)	۰/۰۰۰۰۲۶۳	۰/۰۰۵۱۳

منبع: یافته‌های تحقیق

خروجی‌های سیستم (مقادیر شبیه‌سازی شده یا پیش‌بینی خارج از نمونه) را به دست می‌دهد. بنابراین، بر اساس سیستم استنتاج فازی *gaussmf* به برآورد میزان خطای پیش‌بینی شبکه عصبی فازی در پیش‌بینی خارج از نمونه شاخص بازدهی بورس در دو مدل ANFIS مجزا، که در هر دوی آنها ۵ وقفه از متغیر وابسته به همراه متغیر مجازی که در برگزیده شکست‌های ساختاری موجود در سری بازدهی بورس در دوره مورد بررسی وجود داشته، می‌پردازیم که نتایج آن در جدول ۴ ارائه شده است. نتایج جدول فوق نیز نشان می‌دهد که، نتایج مدل شبکه عصبی فازی مبتنی بر داده‌های ورودی ۵ وقفه از متغیر وابسته به همراه متغیر مجازی، به لحاظ خطای پیش‌بینی کمتر، از عملکرد بهتری نسبت به مدل‌های با داده‌های ورودی ۵ وقفه از متغیر وابسته، برخوردار می‌باشند.^{۶۷}

برای انتخاب نوع تابع FIS، در جعبه ابزار گرافیکی ANFIS بدین صورت عمل می‌کنیم که، بعلت حجم زیاد داده‌ها، هر تابع را برای تعداد ۵۰ داده (که به صورت رندوم انتخاب شده‌اند)، اجرا نموده و مقادیر واقعی و مقادیر خروجی شبکه را بدست آورده و سپس، خطاهای مربوط به هر تابع را محاسبه نموده و در نهایت سیستم استنتاج فازی (FIS) بهینه را انتخاب نمودیم. نتایج حاکی از آن بوده است که، در تحقیق حاضر، دو تابع FIS گوسی (*gaussmf* و *gauss2mf*) دارای کمترین خطای ممکن و به دنبال آن بیشترین دقت بوده‌اند (با اختلاف ناچیزی عملکرد *gaussmf* بهتر بوده است). پس از انتخاب تابع FIS بهینه، نوبت به انجام مرحله تخمین اولیه که معادل با مرحله یادگیری^{۶۶} برای داده‌های آموزش خواهد رسید، که بر این اساس شبکه بهینه در بخش یادگیری ضرایب توابع را تخمین زده و در این بخش با توجه به آنها مقدار

جدول (۴) میزان خطاهای پیش‌بینی با استفاده از مدل ANFIS

ردیف	مدل	تابع استنتاج فازی	MSE	RMSE
۱	ANFIS (5lag of dltd)	gaussmf	۰/۰۰۰۰۲۹۸	۰/۰۰۵۴۶
۲	ANFIS (5lag of dltd & DUM)	gaussmf	۰/۰۰۰۰۰۶۸	۰/۰۰۲۶۱

منبع: یافته‌های تحقیق

متغیر مجازی^{۶۸} که بیشتر معرفی شد، به عنوان متغیرهای ورودی^{۶۹} مدل گشته است. بر اساس جدول ۶، مدل NNARX(10) (با بکارگیری ده وقفه از سری بازدهی بورس و متغیر مجازی معرفی شده) با توجه به معیارهای R^2 ، MSE و RMSE در بین سایر مدل‌ها از بهترین عملکرد برخوردار بوده است.

۳-۳- برآورد مدل پویا

همانطور که گفته شد، نخستین گام در مدل‌سازی کلیه مدل‌های غیرخطی مبتنی بر شبکه‌های عصبی، تعیین ترکیب بهینه عوامل طراحی شبکه عصبی با همان «معماری شبکه» می‌باشد. بر اساس معماری شبکه که در جدول فوق تبیین گردید، برآورد و مقایسه‌ی انواع مدل‌های مختلف NNARX ارائه می‌گردد، که در آنها همانند مدل‌های پیشین، از یک

جدول (۵): ترکیب بهینه عوامل طراحی شبکه عصبی (معماری شبکه)

ارزش	عامل طراحی
NNAR & NNARX	نوع شبکه
۱۰	تعداد نرون‌های لایه پنهان اول
۱	تعداد نرون‌های لایه پنهان دوم
Feed Forward Network	تابع پیش‌پردازش
LM ۷۰	تابع تبدیل لایه

منبع: گورسن و همکاران (۲۰۱۱)

جدول (۶): نتایج تخمین انواع مدل‌های NNARX

مدل	MSE	RMSE	R2
NNARX (1)	۰/۰۰۰۰۵۳۵	۰/۰۰۷۳۱	۰/۱۷
NNARX(2)	۰/۰۰۰۰۶۷۸	۰/۰۰۸۲۳	۰/۰۹
NNARX(3)	۰/۰۰۰۰۶۷۵	۰/۰۰۸۲۱	۰/۰۸
NNARX(4)	۰/۰۰۰۰۵۶۶	۰/۰۰۷۵۲	۰/۱۲
NNARX(5)	۰/۰۰۰۰۵۳۶	۰/۰۰۷۳۲	۰/۱۷
NNARX(6)	۰/۰۰۰۰۵۵۸	۰/۰۰۷۴۷	۰/۱۴
NNARX(7)	۰/۰۰۰۰۵۴۰	۰/۰۰۷۳۴	۰/۱۷
NNARX(8)	۰/۰۰۰۰۵۵۵	۰/۰۰۷۴۵	۰/۱۸
NNARX(9)	۰/۰۰۰۰۵۴۶	۰/۰۰۷۳۹	۰/۱۷
NNARX(10)	۰/۰۰۰۰۵۲۸	۰/۰۰۷۲۶	۰/۱۹

منبع: یافته‌های تحقیق

۳-۴- مقایسه عملکرد دقت پیش‌بینی مدل‌های تحقیق

بطور کلی معیارهای MSE و RMSE از پرکاربردترین معیارهای مقایسه دقت مدل‌ها در زمینه پیش‌بینی، در میان سایر معیارهای برازش دقت پیش‌بینی، می‌باشند. در بسیاری از مطالعات از معیار RMSE به عنوان بهترین معیار برازش دقت پیش‌بینی مدل‌ها استفاده نموده‌اند، چراکه این معیار در واقع میانگینی از معیار MSE بوده، و تمامی ویژگی معیار MSE، از جمله در نظر گرفتن داده‌های دورافتاده در مقایسه دقت مدل‌ها، را در بردارد و همچنین، این

معیار، به این علت که جذر MSE می‌باشد، اختلاف خطاها را کمتر نشان می‌دهد (سوانسون و همکاران^۱، ۲۰۱۱).

$$MSE = \frac{\sum (\hat{y}_t - y_t)^2}{n} \quad (۶)$$

$$RMSE = \sqrt{\frac{\sum (\hat{y}_t - y_t)^2}{n}} \quad (۷)$$

بنابراین، بر اساس معیارهای ذکر شده به مقایسه عملکرد دقت مدل‌های این تحقیق در پیش‌بینی

خارج از نمونه (۶۰ مشاهده‌ی خارج از نمونه) می-پردازیم، که نتایج آن در جدول (۷) آورده شده است:

جدول (۷): نتایج پیش‌بینی مدل‌های MFNN, ANFIS و NNARX

مدل‌ها	MSE	RMSE
MFNN	۰/۰۰۱۶۰۶	۰/۰۴۰۰۸۲
ANFIS	۰/۰۰۰۰۰۶۸	۰/۰۰۲۶۱
NNARX(10)	۰/۰۰۰۰۵۲۸	۰/۰۰۷۲۶

منبع: یافته‌های تحقیق

نتایج ارائه شده در جدول فوق بیانگر کمتر بودن خطای پیش‌بینی مدل شبکه عصبی ایستای ANFIS نسبت به مدل شبکه عصبی پویای NNARX(10) بوده و همچنین هر دوی این مدل‌ها عملکرد بهتری نسبت به مدل MFNN در پیش‌بینی سری بازدهی بورس اوراق بهادار تهران طی دوره مورد بررسی می‌باشند.

۴- نتیجه‌گیری و بحث

اصولاً یکی از مهمترین نظریه‌های اقتصادی در زمینه بازارهای مالی، نظریه‌ی پیش‌بینی‌ناپذیری تغییرات شاخص‌های قیمت بازار سهام، که در آمار به نظریه‌ی گام تصادفی معروف است، می‌باشد. مدل‌های پیش‌بینی که برای قیمت‌های سهام طراحی شده‌اند، در واقع به عنوان چالشی در مقابل نظریه‌ی فوق مطرح هستند و سعی دارند تا نشان دهند که می‌توان علیرغم پیچیدگی‌های بسیار در روند قیمت-ها، روند آتی آنها را با سطح خطای قابل قبولی پیش‌بینی نمود. از جمله‌ی این مدل‌ها می‌توان به مدل‌های غیرخطی شبکه‌ی عصبی ایستا و پویا اشاره کرد. این مدل‌ها نشان داده‌اند که در زمینه‌ی پیش‌بینی

متغیرهایی که از روند بسیار پیچیده‌ای برخوردار باشند، نسبتاً موفق عمل نموده‌اند.

در این تحقیق نیز به منظور پیش‌بینی بازدهی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران (TEDPIX) از مدل شبکه عصبی اتورگرسیو پویای (NNARX) و نیز مدل‌های شبکه عصبی ایستای فازی (ANFIS) و شبکه عصبی ایستای چند لایه پیشخور (MFNN) استفاده شده است. که نتایج ارائه شده در جدول (۸) نشان می‌دهد که، مدل ANFIS در میان سایر مدل‌های تحقیق، پیش‌بینی دقیق‌تری از شاخص بازدهی بورس طی دوره‌ی زمانی مورد بررسی داشته و پس از آن به ترتیب مدل‌های NNARX و MFNN عملکرد بهتری در پیش‌بینی متغیر مذکور دارند. این نتیجه دور از انتظار نبوده، چراکه نتایج تحقیقات پیشین از جمله مطالعه بافنده‌ایمان‌دوست و همکاران (۱۳۸۸) برتری مدل ANFIS را بر مدل NNARX اعلام نموده و همچنین در مطالعه‌ی دیگری نظیر رجالکشمی^{۲۲} و همکاران (۲۰۱۲) مؤید این امر بوده است.

ذکر این نکته ضروریست که اگر چه همانطور که در این پژوهش بیان گردید، مدل‌های شبکه‌ی عصبی ANFIS و MFNN ایستا نامیده می‌شوند، اما ایستایی این شبکه‌های عصبی تنها از لحاظ ویژگی‌های ذاتی مدل است، در صورتی که متغیرهای ورودی آنها در این تحقیق، مقادیر وقفه‌های مختلف سری مورد بررسی بوده است، لذا، عملکرد این مدل‌ها در طی زمان (به طور پویا) مورد ارزیابی قرار گرفته است. بنابراین، با عنایت به اینکه رویکرد بکارگرفته شده در این تحقیق، کاربردی تک متغیره (تحلیل تکنیکال) از آن بوده، لذا به عنوان پیشنهادی برای مطالعات آتی می‌توان در مطالعات پند متغیر (تحلیل بنیادی) نیز این رویکرد را مورد ارزیابی قرار داد.



سهام) مطالعه موردی: بورس اوراق بهادار تهران"، فصلنامه پژوهش‌های اقتصادی ایران، سال سیزدهم، شماره ۴۰، صفحات ۲۹-۵۷.

* سلیمی‌فر، مصطفی و شیرزور، زهرا (۱۳۸۹): "بررسی کارایی اطلاعاتی بازار بورس به روش آزمون نسبت واریانس"، مجله دانش و توسعه، سال هجدهم، شماره ۳۱.

* فلاح‌شمس، میرفیض و دلنواصغری، بیتا (۱۳۸۸): "پیش‌بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی"، مجله فراسوی مدیریت، سال سوم، شماره ۹.

* فهیمی‌فرد، سید محمد و سالارپور، ماشاء‌الله و صبحی صابونی، محمود، (۱۳۸۹): "کاربرد الگوهای ANFIS در مقایسه با الگوهای اقتصادسنجی ARIMA در پیش‌بینی قیمت خرده‌فروشی محصولات کشاورزی"، اقتصاد کشاورزی، جلد ۴، شماره ۲، صفحات ۱۸۳-۱۶۵.

* فهیمی‌فرد، سید محمد و کیخا، احمدعلی و سالار پور، ماشاء‌الله، (۱۳۸۸): "پیش‌بینی قیمت محصولات منتخب کشاورزی ایران با روش تلفیقی شبکه عصبی- خودرگرسیون با ورودی‌های برونزا (NNARX)"، نشریه اقتصاد و توسعه کشاورزی (علوم و صنایع کشاورزی)، جلد ۲۳، شماره ۲، صفحات ۴۶-۵۴.

* مشیری، سعید و فروتن، فائزه (۱۳۸۳): "آزمون آشوب و پیش‌بینی قیمت آتی نفت خام"، فصلنامه پژوهش‌های اقتصادی ایران، شماره ۲۱، صفحات ۶۷-۹۰.

* مشیری، سعید و مروت، حبیب (۱۳۸۴): "بررسی وجود فرآیند آشوبی در شاخص بازدهی کل قیمت سهام بازار بورس تهران"،

در پایان می‌توان استفاده از روش شبکه‌ی عصبی ANFIS را به عنوان یک روش مناسب برای استفاده سیاست‌گذاران و تصمیم‌گیران کلان اقتصادی به منظور اعمال پیش‌بینی‌های هرچه دقیق‌تر و نیز بکارگیری سرمایه‌گذاران برای کسب منافع حاصل از اتخاذ تصمیمات سرمایه‌گذاری مناسب به کمک پیش-بینی‌های کاراتر، معرفی نمود.

فهرست منابع

* آذر، عادل و افسر، امیر، (۱۳۸۵): "مدل سازی پیش‌بینی قیمت سهام با رویکرد شبکه‌های عصبی فازی"، فصلنامه پژوهشنامه بازرگانی، شماره ۴۰، صفحات ۵۲-۳۳.

* بافنده‌ایمان‌دوست، صادق و فهیمی‌فرد، سید محمد و شیرزادی، سمیه، (۱۳۸۸): "پیش‌بینی نرخ ارز با مدل‌های عصبی- فازی ANFIS، شبکه عصبی خودرگرسیونی NNARX و خودرگرسیونی ARIMA در اقتصاد ایران (۸۷-۱۳۸۱)"، مجله دانش و توسعه (علمی-پژوهشی)، شماره ۲۸، صفحات ۱۹۲-۱۷۶.

* تهرانی، رضا و انصاری، حجت‌اله و سارنج، علیرضا (۱۳۸۷): "بررسی وجود پدیده بازگشت به میانگین در بورس اوراق بهادار تهران با استفاده از آزمون نسبت واریانس"، بررسی‌های حسابداری و حسابرسی، دوره ۱۵، شماره ۵۴.

* حیدری‌زارع، بهزاد و کردلوئی، حمیدرضا (۱۳۸۹): "پیش‌بینی قیمت سهام با استفاده از شبکه عصبی مصنوعی"، فصلنامه مدیریت، شماره ۱۷.

* راسخی، سعید و خانعلی‌پور، امیر (۱۳۸۸): "تحلیل تجربی نوسانات و کارایی اطلاعاتی بازار

- Analysis with Neural Network for Prediction Stock Price Index in Tehran Stock Exchange", Middle Eastern Finance and Economics, EuroJournals Publishing, Inc.
- * Melin, P., Soto, J., Castillo, O., Soria, J., (2012): "A new approach for time series prediction using ensembles of ANFIS models", Expert Systems with Applications, Vol. 39, Issue. 3, PP. 3494-3506.
- * Moloney, K., Raghavendra, S., (2011): "Testing for Nonlinear Dependence in the Credit Default SwapMarket", Economics Research International, Vol. 708704, PP. 1-11.
- * Pritam R. Charkha , (2008): " Stock Price Prediction and Trend Prediction using Neural Networks" , First International Conference on Emerging Trends in Engineering and Technology, pp: 592-594, IEEE.
- * Thenmozhi, M., (2006): "Prediction stock index returns using artificial neural networks", Delhi Business Review X, Vol. 7, No. 2.
- * Tong-Seng Q., (2007): "Using Neural Network for DJIA Stock Selection ", Engineering Letters, EL_15_1_19, pp 15:1.
- * Rajalakshmi, M., Saravanakumar, G., Karthik, C., (2012): "Nonlinear Identification of pH Process by Using NNARX Model", International Conference on Computing and Control Engineering, Vol. 12, PP. 1-4.
- * Sutheebanjard ,P. and Premchaiswad , W.i, (2010): "Stock Exchange of Thailand Index predictionusing Back Propagation Neural Networks", Second International Conference on Computer and Network Technology, pp: 377-380, IEEE.
- * Swanson, D.A., Tayman,J., Bryan, T.M., (2011): "MAPE-R: a Rescaled Measure of Accuracy for Cross-Sectional Subnational Population Forecasts", J Pop Research, Vol. 28, PP. 225-243.
- * Wanous, M., Boussabaine, H., Lewis, J., (2003): "A Neural Network Bid/No Bid Model: the Case for Contractors in Syria", Construction Management and Economics, Vol. 21, 737-744.
- فصلنامه پژوهش‌های اقتصادی ایران، شماره ۲۵، صفحات ۴۷-۶۴.
- * مشیری، سعید و مروت، حبیب (۱۳۸۵): "پیش-بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیرخطی"، فصلنامه پژوهشنامه بازرگانی.
- * Al-Khazali, O.M., Pyun, C.S., Kim, D., (2011): "Are Exchange Rate Movements Predictable in Asia-Pacific Markets? Evidence of Random Walk and Martingale Difference Processes", International Review of Economics and Finance, Vol. 21, PP. 221-231.
- * Briatka, L., (2006): "How Big is Big Enough? Justifying Results of the i.i.d Test Based on the Correlation Integral in the Non-Normal World", Working Paper Series, ISSN. 1211-3298, No. 308, PP. 1-34.
- * Dase R.K. and Pawar D.D, (2010): "Application of Artificial Neural Network for stock Market Predictions: A review of literature", International Journal of Machine Intelligence, ISSN: 0975-2927, Vol. 2, Issue. 2, PP. 14-17.
- * Georgescu, V., Dinuca, E.C., (2005): "Evidence of Improvement in Neural-Network Based Predictability of Stock Market Indexes through Co-movement Entries", Recent Advances in Applied & Biomedical Informatics and Computational Engineering in Systems Applications, Vol. 200585, PP. 412-417.
- * Granger, C.W.J & Timmermann, A., (2004): "Efficient market hypothesis and forecasting", International Journal of Forecasting, pages.15-27.
- * Jibendu Kumar Mantri , Dr. P.Gahan and B.B.Nayak, (2010): "Artificial neural networks- an application to stock market volatility", International Journal of Engineering Science and Technology, Vol. 2(5), pp. 1451-1460.
- * Li F., Liu C. , (2009): "Application Study of BP Neural Network on Stock Market Prediction", Ninth International Conference on Hybrid Intelligent Systems, pp: 174-178 , IEEE.
- * Mehrara M. , Moeini A. , Ahrari M. and Ghafari A. , (2010): "Using Technical

- 48- Multi-Branch Artificial Neural Networks
 49- Adaptive Neuro-Fuzzy Inference Systems
 50- Adaptive Nero Fuzzy Inference System
 51- Feed Forward Neural Network
 52- Tehran exchange dividend price index
 53- Lo and MacKinlay
 54- Martingale
 55- Bley
 56- Al-Khazali & Pyun & Kim
 57- Correlation integral
 58- Briatka
 59- Olmedo
 60- Moloney & Raghavendra
 61- Conjugate Gradient Polak-Ribière
 62- Dummy Variable
 63- ANFIS یک واژه‌ی اختصاریست که از حروف اول Adaptive Neuro-Fuzzy Inference System گرفته شده است.
 64- یعنی داده‌ها به اعدادی بین صفر و یک تبدیل شده تا جعبه ابزار گرافیکی ANFIS قادر به خواندن آنها باشد.
 65- که عبارتند از: 1- psigmf ؛ 2- dsigmf ؛ 3- pimf ؛ 4- gauss2mf ؛ 5- gaussmf ؛ 6- gbellmf ؛ 7- trapmf ؛ 8- trimf ؛ 9- Train now
 66- لازم به ذکر است که، با عنایت به عدم در نظرگیری داده‌های اعتبارسنجی (Validation Data) در مدل شبکه عصبی فازی، در سایر مدل‌ها نیز این مقدار معادل صفر در نظر گرفته شده و جهت آزمون عملکرد مدل‌های مختلف، تنها از داده‌های آزمون (Test Data) استفاده گردیده است.
 68- Dummy Variable
 69- Exogenous Variable
 70- Levenberg-Marquardt
 71- Swanson, Tayman & Bryan
 72- Rajalakshmi
 1- Univariable
 2- Mean Square Error
 3- Root Mean Square Error
 4- Information Economics
 5- در ابتدایی‌ترین شکل این فرضیه بیان می‌شود، همه ما به دنبال پیش‌بینی بازده دارایی‌های مالی هستیم که البته غیرقابل پیش‌بینی می‌باشد.
 6- Garanjer & Timmermann
 7- آموزش دیدن شبکه‌های عصبی در واقع چیزی جز تنظیم وزن‌های ارتباطی این نرون‌ها به ازای دریافت مثال‌های مختلف نیست، تا خروجی شبکه به سمت خروجی مطلوب همگرا شود.
 8- Classification
 9- Function Approximation
 10- Prediction
 11- Clustering
 12- Optimization
 13- Artificial Neural Network
 14- Feedback
 15- Feed forward
 16- Data- driven self- adaptive methods
 17- Model free
 18- Universal functional approximates
 19- Output layer
 20- Input layer
 21- Rumelhart
 22- Nielson
 23- Cybenko
 24- Fanahashi
 25- Hornik
 26- White
 27- این نظریه ابتدا با مخالفت‌هایی روبرو گشت ولی به مرور ارزش آن مشخص شد و کاربردهای آن آشکار گردید، به طوریکه امروزه در تمامی زمینه‌ها (از قبیل تمامی سیستم‌های پیشرفته کنترل نظیر کنترل فرآیند صنعتی، کنترل اتومبیل، کنترل ترافیک، کنترل سرعت قطار، سیستم‌های نظامی و نیز خانگی نظیر ماشین‌های لباسشویی، یخچال، اجاق‌های میکرو ویو و دوربین‌های تصویربرداری و ...) کاربرد پیدا کرده است.
 28- Wanous & Boussabaine & Lewis
 29- Fuzzification
 30- Aggregation
 31- Defuzzyfication
 32- Target
 33- Levenberg-Marquardt
 34- Biases
 35- Melin & et al.
 36- Gursen & Kayakutlu & Daim
 37- Soni
 38- Dase & Pawar
 39- Jibendu
 40- Li & Liu
 41- Pritam
 42- Thenmozhi
 43- Stheebanjard & Premchaiswad
 44- Mehrara & Moeini & Ahrari & Ghafari
 45- Tong-Seng
 46- Back Propagation Neural Network
 47- Group Method Of Data Handling