

مقایسه قابلیت‌های مدل‌های مبتنی بر حافظه بلندمدت و مدل‌های شبکه عصبی پویا در پیش‌بینی بازدهی بورس اوراق بهادار تهران

اکبر کمیجانی^۱

اسماعیل نادری^۲

تاریخ پذیرش: ۹۱/۲/۲۰

تاریخ دریافت: ۹۰/۱۲/۱

چکیده

این مقاله با هدف معرفی یک الگوی مناسب جهت پیش‌بینی شاخص بازدهی بورس اوراق بهادار تهران صورت پذیرفته است. داده‌های مورد استفاده در این پژوهش به صورت روزانه و شامل بازه‌ی زمانی پنجم فروردین ۱۳۸۸ تا سی‌ام آبان ۱۳۹۰ که مشتمل بر ۶۱۶ مشاهده بوده که جهت مجزا سازی پیش‌بینی‌های داخل نمونه‌ای و خارج از نمونه‌ای، از تقریباً ۹۰٪ از مشاهدات (۵۵۶ مشاهده) جهت تخمین ضرایب مدل و از مابقی (۶۰ مشاهده) جهت انجام پیش‌بینی خارج از نمونه استفاده شده است. همچنین الگوهای مورد استفاده در این پژوهش عبارتند از؛ یک مدل غیرخطی شبکه‌ی عصبی مصنوعی پویا (شبکه عصبی خودرگرسیون^۱) و نیز یک مدل رگرسیونی غیرخطی (مدل خودرگرسیونی میانگین متحرک انباشته‌ی کسری^۲). یافته‌های این پژوهش نشان می‌دهد که مدل شبکه‌ی عصبی مصنوعی پویا در پیش‌بینی‌های خارج از نمونه، بر اساس معیارهای محاسبه‌ی خطای پیش‌بینی میانگین مجذور خطا (MSE)^۳ و نیز معیار جذر میانگین مجذور خطا (RMSE)^۴، دارای عملکرد بهتری نسبت به مدل رگرسیونی غیرخطی ARFIMA می‌باشند.

واژه‌های کلیدی: پیش‌بینی، بازار بورس، مدل ARFIMA، مدل NNAR.

۱- استاد دانشکده اقتصاد دانشگاه تهران، komijani@ut.ac.ir

۲- دانشجوی کارشناسی ارشد دانشکده اقتصاد دانشگاه تهران (مسئول مکاتبات)، Naderi.ec@ut.ac.ir

۱- مقدمه

یکی از ویژگی‌های حرکت به سوی توسعه اقتصادی، این است که مجموعه اقتصاد، بتواند منابع پس انداز را به سوی سرمایه‌گذاری‌های مورد نیاز اقتصاد ملی هدایت نموده و در صورت وجود مازاد منابع، آن را به سمت سرمایه‌گذاری‌های خارجی گسیل نماید. به طور کلی، وظیفه تجهیز منابع پس انداز به سوی سرمایه‌گذاری مورد نیاز، توسط بازار پول و بازار سرمایه انجام می‌شود. البته در نخستین مراحل توسعه، بازار پول نقش اساسی را در تجهیز منابع پس انداز به عهده داشته، اما به تدریج، و با توسعه اقتصاد، بازار سرمایه بخش فزاینده‌ای از پس اندازها را به سوی سرمایه‌گذاری‌های مولد، هدایت می‌کند.

از سوی دیگر پیش‌بینی متغیرهای کلان اقتصادی از اهمیت و جایگاه ویژه‌ای در مباحث علمی اقتصاد برخوردار است و مدل‌های مختلفی جهت پیش‌بینی مقادیر آتی متغیرها به وجود آمده‌اند، تا سیاست‌گذاران اقتصادی را در اتخاذ سیاست‌های پولی و مالی مناسب یاری نمایند. همچنین، با توجه به مقوله «اقتصاد اطلاعات»^۵ و بحث‌های مربوط به وجود اطلاعات نامتقارن در بازارهای مالی و در نتیجه پیچیدگی‌های ناشی از تحلیل اثرات انواع متغیرها بر شاخص بورس در چنین شرایطی، سبب شده تا ارزش مقوله پیش‌بینی بیشتر و بیشتر گردد. یکی از مهمترین کارکردهای مدل‌های اقتصادی، پیش‌بینی مقادیر آتی متغیرهای اقتصادی می‌باشد. 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. چنین حقیقتی سبب شده است تا تحقیقات در زمینه مدل‌ها و تکنیک‌های پیش‌بینی در چند دهه اخیر با شتاب بیشتری مواجه گردد، بطوری که امروزه در ادبیات اقتصادسنجی و اقتصاد کاربردی، شاهد مدل‌ها و روش‌های بسیاری در این زمینه می‌باشیم.

بنابراین آنچه در این پژوهش بررسی خواهد شد، مقایسه مدل‌های مختلف (مدل‌های مبتنی بر حافظه بلندمدت^۶ و مدل شبکه عصبی مصنوعی) 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) جهت انجام تخمین‌ها و از ۶۰ مشاهده جهت انجام پیش‌بینی خارج از نمونه استفاده شده است.

۲- مبانی نظری و مروری بر پیشینه پژوهش

با توجه به رشد روزافزون بازارهای مالی، وجود هرگونه تغییراتی در این بازارها می‌تواند، آثار شگرفی بر کل اقتصاد جهانی بگذارد. به طور کلی این تغییرات می‌تواند از حوادث اقتصادی، اجتماعی، فرهنگی و نیز سیاسی نشأت پذیرد، که این امر سبب سردرگمی شدید سرمایه‌گذاران و ایجاد نااطمینانی در مورد عملکرد بازارهای مالی شده و در نتیجه اعتماد عمومی سرمایه‌گذاران به این بازارها کاهش یافته و اثرات منفی زیادی بر اقتصاد جهانی خواهد گذاشت. این مطلب شاهد آشکاری بر رابطه قوی بین نااطمینانی بازارهای مالی و اعتماد عمومی سرمایه‌گذاران می‌باشد. به

این دلیل سیاستگذاران مالی کشورها، اغلب به برآورد و پیش‌بینی دقیق تغییرات قیمت‌های بازارهای مالی به عنوان معیاری جهت اتخاذ سیاست مناسب برای کاهش آسیب‌پذیری اقتصاد ملی و جهانی نیاز دارند. بنابراین پیش‌بینی تغییرات قیمت دارایی‌های مالی یکی از مهمترین وظایف در بازارهای مالی بوده که توجه محققان و سیاستگذاران را در طی دو دهه اخیر به خود جلب کرده است تا آنها بتوانند از این پیش‌بینی‌ها در ارزیابی و قیمت‌گذاری دارایی‌ها، تخصیص بهینه منابع مالی و ارزیابی عملکرد مدیریت ریسک استفاده نمایند.

بررسی کارایی بورس اوراق بهادار

نخستین گام در انجام پیش‌بینی یک سری از داده‌ها، بررسی قابلیت پیش‌بینی پذیری آن می‌باشد. از این رو 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 جهت پیش‌بینی قیمت سهام به دلیل عوامل متعدد تأثیر گزار بر آن سبب ارایه «فرضیه کارایی بازار» شد^۷ (گرنجر و تیمرمن^۸، 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 تیمرمن، 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 مطالعه‌ی مشیری و فروتن، ۱۳۸۳). رد فرضیه کارایی بازار سهام، مهر تأییدی بر قابلیت پیش‌بینی-پذیری سری بازدهی سهام، به کمک مدل‌های غیرخطی (از جمله مدل‌های بکار برده شده در این

پژوهش) خواهد داشت. در بخش بعدی به تبیین مدل‌های سری‌زمانی غیرخطی می‌پردازیم.

مروری بر پیشینه پژوهش

اصولاً پیش‌بینی شاخص بازدهی سهام به علت تأثیرپذیری شدید آنها از بسیاری از عوامل اقتصادی و غیر اقتصادی، در زمره پیچیده‌ترین موارد جهت 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.

الاگیدو^۹ (۲۰۱۱) به بررسی رفتار بازده در بازارهای سهام آفریقا با بکارگیری مدل‌های دارای ویژگی حافظه بلندمدت پرداخته است. نتایج این تحقیق ضمن تأیید وجود ویژگی حافظه‌ی بلندمدت در داده‌های این بازار، وجود نوسانات خوشه‌ای و نیز اثرات اهرمی را در داده‌های مورد بررسی نشان می‌دهند. کیتیکاراساکون و تسه^{۱۰} (۲۰۱۱) نیز با استفاده از مدل‌های ARFIMA-^{۱۱} FIGARCH بازارهای سهام آسیا را که دارای توزیع پهن دنباله بوده‌اند را مورد تجزیه و تحلیل قرار دادند. نتایج این تحقیق نشان می‌دهند که این بازارها از ویژگی‌های مهم بازارهای مالی یعنی حافظه بلندمدت برخوردار هستند.

همچنین در سال ۲۰۱۱، گورسن و همکاران^{۱۲} در مقاله‌ی خود در پی بهبود عملکرد مدل‌های خطی و غیرخطی سنتی، با وارد کردن تلاطم موجود در سری داده‌های شاخص "نزدک"^{۱۳} به عنوان متغیر ورودی بر آمدند. گئورگسکو و دینوکا نیز در سال ۲۰۰۵، با بکارگیری شبکه عصبی سری‌زمانی (الگوریتم NNARX)، به پیش‌بینی در

بازارهای سهام رومانی پرداختند. که نتایج آن بیانگر کارایی بیشتر مدل‌های شبکه عصبی سری‌زمانی (NNARX) نسبت به مدل‌های غیرخطی رگرسیونی در بازارهای سهام رومانی بوده است.

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. فهیمی‌فرد و همکاران (۱۳۸۹) نیز با استفاده از شبکه عصبی رویکرد فازی (ANFIS)^{۱۴} و ARIMA به پیش‌بینی قیمت خرده‌فروشی محصولات کشاورزی پرداخته‌اند. همچنین، بافنده‌ایمان‌دوست و همکاران (۱۳۸۸) به پیش‌بینی نرخ ارز با استفاده از مدل‌های عصبی-فازی ANFIS، شبکه عصبی خودرگرسیونی NNARX و خودرگرسیونی ARIMA پرداخته‌اند. نتایج این تحقیق بیانگر کارایی بالاتر مدل‌های شبکه عصبی نسبت به مدل‌های سری‌زمانی و خودرگرسیونی بوده است. فلاح‌شمس و دلنواز اصغری (۱۳۸۸) در مقاله‌ای به مقایسه‌ی مدل‌های شبکه عصبی پیش‌خور^{۱۵} و مدل‌های ARIMA پرداختند.

عرفانی (۱۳۸۸) در مقاله‌ای به مقایسه‌ی عملکرد پیش‌بینی مدل ARFIMA با مدل ARIMA پرداخت، که نتایج این پژوهش نشان داد که این سری از نوع حافظه بلندمدت می‌باشد. مقایسه عملکرد پیش‌بینی مدل‌های ARIMA و ARFIMA دال بر بالاتر بودن قدرت پیش‌بینی کنندگی مدل ARFIMA می‌باشد. همچنین، کشاورز حداد و صمدی (۱۳۸۸) در پژوهش خود با توجه به وجود علائم حافظه بلندمدت جهت

تبین میانگین شرطی، از مدل ARFIMA و برای واریانس شرطی، در کنار مدل‌های با حافظه کوتاه-مدت، از مدل با حافظه بلندمدت FIGARCH استفاده نموده است. محمدی و طالبلو (۱۳۸۹) به بررسی پویایی تورم و رابطه تورم و عدم اطمینان اسمی با استفاده از الگوی^{۱۶} ARFIMA-GARCH پرداخته‌اند.

۳- مدل‌های پژوهش

مدل‌های سری زمانی

اساساً یکی از اهداف اساسی مدل‌های اقتصادی، پیش‌بینی صحیح و دقیق متغیرهای اقتصادی جهت یاری‌رسانی به سیاست‌گذاران در اتخاذ تصمیمات صحیح و متناسب می‌باشد. از آنجا که روش‌های مختلفی برای پیش‌بینی در اقتصاد وجود دارند، می‌توان آنها را بر اساس قالب‌های مختلفی نیز تقسیم‌بندی نمود که مهم‌ترین آنها عبارتند از: ۱) تقسیم‌بندی بر اساس الگوهای خطی^{۱۷} و الگوهای غیرخطی^{۱۸} تقسیم‌بندی بر اساس الگوهای ساختاری و الگوهای سری‌زمانی (مشیری، مروت، ۱۳۸۵).

اگرچه مدل‌های ساختاری در تبیین وضع موجود از موفقیت نسبی برخوردار بودند ولی در زمینه پیش‌بینی سابقه چندان موفقی نداشتند، ولی در مقابل مدل‌های سری‌زمانی نتایج از مراتب بهتری برخوردار بوده‌اند. همچنین با توجه به اینکه افزایش دقت، صحت و کارایی مدل‌های پیش‌بینی مستلزم بکارگیری مدل‌های پیچیده‌تری است که بتواند رفتار سری‌های زمانی را به نحو صحیح‌تری توضیح دهد، از این‌رو در سالهای اخیر توجه اقتصاددانان به مدل‌های غیرخطی معطوف گشته

است و نیز با توجه به اینکه مدل‌های با حافظه بلندمدت بیانگر ساختار غیرخطی بازارها می‌باشند و مؤید این مطلب هستند که مدل‌های خطی در توصیف ماهیت این بازارها ناکارآمد هستند (ایکسو و جین^{۱۹}، ۲۰۰۶)، بنابراین مدل‌های خطی نظیر AR^{۲۰}، MA^{۲۱} و ARIMA^{۲۲} ویژگی حافظه بلندمدت یک متغیر را در نظر نگرفته ولی در مقابل مهمترین و انعطاف‌پذیرترین گروه از مدل‌های دارای حافظه بلندمدت که علاوه بر اینکه مشکل مزبور را مرتفع می‌سازند، می‌توانند رفتار پایدار و ناپایدار تولید نمایند، عبارتند از مدل ARFIMA که جهت تبیین رفتار «معادله میانگین^{۲۳}» بکار گرفته می‌شود^{۲۴} (مشیری، ۱۳۸۱).

علاوه بر این، پیش‌بینی براساس مدل‌های غیرخطی اقتصادسنجی نیز با محدودیت‌های بسیار زیادی همراه است^{۲۵}. در حالی‌که مدل‌های جدید شبکه عصبی می‌توانند برازش بهتری از مدل‌های خطی و غیرخطی اقتصادسنجی داشته باشند. 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. شبکه‌های عصبی شامل دو دسته‌ی شبکه‌های پویا و ایستا می‌باشند. شبکه‌های ایستا مانند شبکه عصبی - مصنوعی (ANN)^{۲۶} عامل پسخور^{۲۷} نداشته و در نتیجه شامل موارد تاخیری نمی‌شوند و خروجی در آنها بصورت مستقیم بوسیله ورودی-هایی که ارتباط پیشخور^{۲۸} دارند محاسبه می‌شود. اما در شبکه‌های عصبی پویا مانند مدل شبکه عصبی-خودرگرسیون با متغیرهای برونزا (NNARX)، خروجی به مقادیر جاری و گذشته

ورودی‌ها، خروجی‌ها و نیز ساختار شبکه بستگی دارد.

مفهوم حافظه بلندمدت و مدل‌های مبتنی بر آن

بعد از مطالعات مهم در مورد وجود ریشه واحد^{۲۹} و همجمعی^{۳۰} در سری‌های زمانی که از اواسط دهه ۱۹۸۰ آغاز شده بود اقتصادسنجی‌دانان زیرگونه‌ها و انواع دیگری از نامانایی و پایداری^{۳۱} تقریبی را که فرآیند موجود در بسیاری از سری-های زمانی مالی و اقتصادی را توجیه می‌کردند، را مورد بررسی قرار دادند. بطوریکه امروزه مطالعات گوناگونی در مورد این نوع از فرآیندها از جمله حرکت کسری براونی^{۳۲}، فرآیندهای انباشته جزئی^{۳۳} و فرآیندهای با حافظه بلندمدت صورت گرفته است (کریمیان، ۱۳۸۷). هِرست^{۳۴} (۱۹۵۱) برای اولین بار به وجود فرآیندهای دارای حافظه بلندمدت در زمینه آب‌شناسی پی برد. بعد از وی و از اوایل دهه ۱۹۸۰ اقتصادسنجی‌دانانی مانند گرنجر و جویکس^{۳۵} (۱۹۸۰) و هاسکینگ^{۳۶} (۱۹۸۱) به طراحی مدل‌های اقتصادسنجی با ویژگی حافظه بلندمدت پرداخته و ویژگی‌های آماری این مدل‌ها را مشخص نمودند (مشیری و مروت، ۱۳۸۵).

حافظه بلندمدت، به یک وابستگی قوی میان مشاهدات دور در یک سری زمانی منتسب می‌شود. (مشیری و مروت، ۱۳۸۵) به طور کلی مهم‌ترین مشکلی که در اثر وجود متغیرهای نامانا ممکن است ایجاد شود، وجود رگرسیون کاذب است، از سوی دیگر با توجه به اینکه بیشتر سری‌های زمانی اقتصادی و مالی نامانا از نوع DSP^{۳۷} (تفاضل مانا) هستند، برای رفع این مشکل نخست باید مرتبه تفاضل‌گیری هر متغیر را تعیین نمود. اما این کار

موجب از دست رفتن بخشی از اطلاعات مهم موجود در گشتاور اول (معادله میانگین) و گشتاور مرتبه دوم (معادله واریانس^{۳۸}) سری زمانی می‌شود. به طوری که قبل از دستیابی به مانایی سری‌زمانی، واریانس سری روندی کاهشی داشته و هنگامی که تفاضل‌گیری بیش از حد انجام شود، واریانس سری مجدداً افزایش خواهد یافت (ایکسو و جین، ۲۰۰۷). از این رو اگر بخواهیم به طور همزمان، هم سری زمانی را مانا نموده و هم دچار مشکل بیش تفاضل‌گیری نشویم، می‌توانیم از تفاضل‌گیری کسری^{۳۹} استفاده نمائیم. پارامتر تفاضل‌گیری کسری می‌تواند مقادیر مختلفی را به خود اختصاص دهد ولی مقدار خاصی از این پارامتر (d)، بیانگر ویژگی حافظه بلندمدت می‌باشد.

مهم‌ترین قدم در برآورد یک مدل با ویژگی حافظه بلندمدت بررسی وجود این ویژگی در سری‌های مربوطه است. شناسایی وجود ویژگی حافظه بلندمدت از طریق روش ترسیمی (آزمون ACF^{۴۰}) و نیز تکنیک‌هایی شامل روش‌های گرافیکی (تحلیل R/S^{۴۱} کلاسیک، روش واریانس متراکم شده)، روش‌های نیمه پارامتری (روش GPH^{۴۲} و MRS^{۴۳}) و روش‌های پارامتری (روش برآورد درست‌نمایی ماکزیمم برشی) امکان‌پذیر می‌باشد. که در این میان روش GPH از عملکرد بهتری برخوردار می‌باشد. بنابراین پس از تأیید وجود حافظه بلندمدت در فرآیند تولید داده‌ها، به کمک مدل ARFIMA می‌توان گشتاور مرتبه‌ی اول آنها را مدل‌سازی نمود^{۴۴}. بر این اساس، در ادامه به تبیین مدل ARFIMA خواهیم پرداخت.

معروف‌ترین و انعطاف‌پذیرترین مدل حافظه بلندمدت مدل ARFIMA بوده، در این مدل درجه همجمعی کسری (d) را پارامتر حافظه بلندمدت

خواهد بود (هاسکینگ، ۱۹۸۱). زمانی که $0 < d < 0.5$ باشد؛ تابع خودهمبستگی به صورت هیپربولیکی کاهشی می‌یابد، و زمانی که $0 < d < 0.5$ - باشد؛ فرآیند حافظه میان‌مدت پیش می‌آید. فرآیند حافظه میان‌مدت نشان دهنده این مطلب است که، از متغیر مورد بررسی بیش از حد تفاضل‌گیری شده و در این مورد معکوس تابع خودهمبستگی به صورت هیپربولیکی^{۴۵} کاهش می‌یابد.

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:

(۳)

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

که در آن f یک نگاشت انجام گرفته بوسیله شبکه عصبی می‌باشد. ورودی‌های شبکه عصبی

گویند، چراکه ناظر بر ویژگی‌های بلندمدت سری زمانی متغیر مورد نظر است. (محمادی و طالب‌لو، ۱۳۸۹) مهمترین مرحله اجرای مدل ARFIMA، مرحله تفاضل‌گیری کسری است. به دلیل مشکل بودن آن معمولاً اقتصاددانان در تحلیل‌های تجربی خود از تفاضل‌گیری مرتبه اول استفاده می‌کنند. بدون شک چنین جایگزینی‌ای منجر به بیش تفاضل‌گیری شده و در پی آن از دست رفتن بخشی از اطلاعات موجود در سری زمانی خواهد شد. (عرفانی، ۱۳۸۷) تصریح مدل ARFIMA (p, d, q) به صورت زیر می‌باشد:

(۱)

$$\phi(L)(1-L)^d(y_t - \mu_t) = \theta(L)\varepsilon_t \quad t = 1, 2, 3, \dots, T$$

که در آن $\phi(L)$ چندجمله‌ای خودهمبستگی، $\theta(L)$ چندجمله‌ای میانگین متحرک، L عملگر وقفه و μ_t میانگین y_t می‌باشند. p و q اعداد صحیح هستند و d عدد واقعی می‌باشد. $(1-L)^d$ معرف عملگر تفاضل کسری است که با استفاده از فرمول زیر محاسبه می‌شود:

(۲)

$$(1-L)^d = \sum_{j=0}^{\infty} \delta_j L^j = \sum_{j=0}^{\infty} \binom{d}{j} (-L)^j$$

در این معادله فرض شده است که $\varepsilon_t \sim N(0, \sigma_{\varepsilon_t}^2)$ و همچنین بخش ARMA مدل معکوس‌پذیر می‌باشد. همچنین، در معادله‌ی (۱) $Z_t = y_t - \mu_t$ بوده و همجمع از مرتبه d می‌باشد. ویژگی‌های Z به ارزش و مقدار d بستگی دارد. اگر $d < 0.5$ باشد؛ کوواریانس مدل ثابت بوده، و اگر $d > 0.5$ باشد؛ دارای ویژگی حافظه بلندمدت

فرآیند آموزش را آغاز می‌کند. و پس از تعیین خروجی مدل جهت 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 جهت عکس (خروجی به ورودی)، تصحیح می‌شود (فهیمی فرد و همکاران، ۱۳۸۸).

تابع آموزش این شبکه Levenberg-Marquardt (LM) بوده، که در این نوع تابع آموزش، مقادیر وزن‌ها و اریب‌ها^{۴۸} بر اساس روش LM بهینه‌سازی به هنگام می‌شوند. همچنین، تابع یادگیری این شبکه GMD^{۴۹} بوده، که تغییرات وزن (dW) یک نرون مشخص را بر اساس ورودی (p) و خطای (E) به نرون، نرخ آموزش وزن یا اریب (LR) و ثابت نیروی حرکت آنی^{۵۰} (MC) بصورت زیر محاسبه می‌کند:

(۴)


$$dW = MC * dW_{prev} + (1 - MC) * LR * gW$$

که در آن dW_{prev} و gW به ترتیب تغییرات وزن پیشین و شیب متناسب با کارایی می‌باشد. علاوه بر این، تابع فعال‌سازی و تابع کارایی خطای پیش فرض برای این نوع شبکه عصبی به ترتیب تانژانت هیپربولیک و میانگین مجذور خطا (MSE) می‌باشد. (فهیمی فرد و همکاران، ۱۳۸۸).

شامل دو بخش وقفه‌های ورودی (سیگنال‌های ورودی) برونزای $u(t)$ و وقفه‌های مقادیر هدفی^{۴۶} (وقفه‌های سیگنال‌های خروجی) $y(t)$ می‌باشند. اعداد n_y و n_u به ترتیب وقفه‌های ورودی برونزا و مقادیر واقعی هدف بوده، که بوسیله سیستم شبکه عصبی تعیین می‌گردند. ساختار شبکه عصبی پویا برای سیستم یک ورودی و یک خروجی (SISO)^{۴۷} که در شکل زیر نشان داده شده است (بافنده‌ایمان‌دوست و همکاران، ۱۳۸۸).

همانگونه که شکل ۱ نشان می‌دهد، این مدل حالت موازی با سیستم داشته و در آن از خطای پیش‌بینی جهت اصلاح پارامترهای مدل، به منظور افزایش کارایی مدل، استفاده می‌شود. همچنین، این مدل، به عنوان یک مدل سری- موازی شناخته شده و در طول آموزش، ورودی‌ها و خروجی‌ها شبکه مستقل از یکدیگر می‌باشند. یک روش دیگر جهت بکارگیری مقادیر واقعی هدف در شبکه، استفاده از وقفه‌های مقادیر پیش‌بینی شده یا خروجی شبکه $\hat{y}(t)$ می‌باشد، که بر این اساس می‌توان به مدل NNAR دست یافت.

مزیت استفاده از این مدل، قابلیت پیش‌بینی‌های بلندمدت دقیق‌تر، در شرایط یکسان، نسبت به مدل ANN می‌باشد. نحوه‌ی آموزش در این نوع شبکه-ها، مبتنی بر قانون یادگیری تصحیح خطا بوده، که با استفاده از مجموعه وزن‌های تصادفی اولیه،



شکل (۱): ساختار سری- موازی مدل NNARX (منبع: بافنده‌ایمان‌دوست و همکاران (۱۳۸۸))

۴- نتایج پژوهش

آنچه در این پژوهش مورد بررسی قرار می‌گیرد، مقایسه‌ی عملکرد مدل ARFIMA و NNAR در پیش‌بینی بازدهی شاخص قیمت و بازده نقدی (TEDPIX^{۵۱}) در بورس اوراق بهادار تهران می‌باشد. لازم به ذکر است که در این پژوهش از نرم‌افزارهای MATLAB، Eviews، S-Plus و Excel استفاده شده است. همچنین علائم اختصاری متغیرهای بکاربرده شده در این مقاله عبارتند از: TEDPIX؛ بیانگر شاخص قیمت و بازده نقدی، dltd؛ تفاضل لگاریتم شاخص قیمت و بازده نقدی (سری بازدهی بورس اوراق بهادار تهران). بر این اساس، با توجه به اینکه، نخستین گام در مدل‌سازی داده‌های سری‌زمانی، بررسی مانایی متغیرها جهت جلوگیری از ایجاد رگرسیون کاذب می‌باشد. در این مقاله نیز نخست به بررسی مانایی سری dltd به کمک آزمون‌های مختلف پرداخته شده است که نتایج آن در جدول ۱ ارائه شده است.

در صورت عدم وجود ویژگی حافظه‌ی بلندمدت، انتظار ما بر آن است که سری مذکور با تفاضل‌گیری (یک مرتبه) مانا شود، اما نتایج حاصل


از یک مرتبه تفاضل‌گیری نشان می‌دهد که، سری بازدهی بورس (سری حاصل از تفاضل‌گیری از لگاریتم شاخص قیمت و بازده نقدی بورس) با توجه به آزمون‌های مانایی ADF^{۵۲} و فیلیپس-پرون^{۵۳} و نیز آزمون ERS^{۵۴} مانا بوده، در حالی که نتیجه‌ی همین آزمون با آماره‌ی KPSS^{۵۵} بیانگر نامانایی سری مذکور می‌باشد که نتایج آن در جدول (۱) ارائه شده است. وجود چنین شرایطی ما را بر آن داشت که، به بررسی ویژگی حافظه‌ی بلندمدت در سری بازدهی بورس (تفاضل‌گیری کسری از سری مذکور) بپردازیم. همچنین بررسی نمودار خودهمبستگی (ACF) نیز می‌تواند دلیل دیگری بر وجود ویژگی حافظه‌ی بلندمدت در سری بازدهی بورس باشد، چرا که همانطور که شکل (۲) نشان می‌دهد، خودهمبستگی موجود میان وقفه‌های مختلف این سری حتی پس از حدود سی (۳۰) دوره از بین نرفته است و در واقع این خودهمبستگی‌ها به صورت خیلی آهسته در حال کاهش است. که این امر مغایر رفتار موجود در نمودارهای خودهمبستگی سری‌های مانا می‌باشد که به صورت نمایی، خودهمبستگی موجود میان وقفه‌های مختلف آنها، کاهش می‌یابد.

جدول (۱): نتایج مربوط به بررسی مانایی در سری بازدهی بورس

متغیر	آزمون	آماره بحرانی	آماره محاسباتی (در سطح ۵٪)	نتیجه آزمون
Dltd	ADF	-۱۶/۵۸۶۹	-۱/۹۴۱۳	مانا
	ERS	-۱۷/۲۸۸۱	-۱/۹۴۱۳	مانا
	فیلیپس-پرون	-۱۷/۵۴۳۷	-۱/۹۴۱۳	مانا
	KPSS	۰/۵۹۰۴	۰/۴۶۳۰	نامانا

منبع: یافته‌های تحقیق

شکل (۲): نمودار ACF سری بازدهی بورس اوراق بهادار تهران



منبع: یافته‌های تحقیق

تخمین پارامتر حافظه بلندمدت

به طور کلی مدل‌های مبتنی بر حافظه‌ی بلندمدت شدیداً به مقدار پارامتر حافظه‌ی بلندمدت و نیز نحوه‌ی میرایی توابع خودهمبستگی بستگی دارد. بر این اساس در زیربخش‌های زیر به تخمین مقدار پارامتر حافظه‌ی بلندمدت با معیار GPH که به کمک نرم‌افزار OX-METRICS انجام شده، خواهیم پرداخت. به طور کلی آزمون GPH که

مبتنی بر تحلیل دامنه فرکانس می‌باشد، از تکنیک رگرسیون دوره نگاشت^{۵۶} استفاده شده که در واقع این تکنیک، ابزاری جهت تمایز بین روندهای کوتاه‌مدت و حافظه بلندمدت فراهم می‌آورد. لازم به ذکر است که، شیب خط رگرسیون حاصل از بکارگیری تکنیک رگرسیون دوره نگاشت، همان پارامتر حافظه بلندمدت را به دست می‌دهد. که مقدار آن در جدول ۲ ارائه گردیده است.

جدول (۲): تخمین مقدار d به کمک آماره‌ی آزمون GPH بر اساس روش NLS

سری	معیار	d-Parameter	t-statistic	Prob
لگاریتم شاخص کل بورس		۱/۰۴۶۹۵	۱۲/۳	۰/۰۰۰
بازدهی بورس		۰/۱۴۰۸۸	۳/۱۳	۰/۰۰۲

منبع: یافته‌های تحقیق

جدول (۳): نتایج تخمین انواع مدل‌های ARFIMA

AIC			مدل
MPL	NLS	EML	
-۷/۲۱۷۱	-۷/۳۲۴۱	-۷/۳۲۳۵	ARFIMA(1,0.14,1)
-۷/۲۱۳۰	-۷/۳۲۸۹	-۷/۳۲۴۲	ARFIMA(1,0.14,2)*
-۷/۲۱۲۴	-۷/۳۲۳۴	-۷/۳۲۲۶	ARFIMA(2,0.14,1)
-۷/۲۱۲۹	-۷/۳۲۵۰	-۷/۳۲۳۶	ARFIMA(2,0.14,2)

منبع: یافته‌های تحقیق

همان‌طور که از نتایج جدول فوق پیداست، مقدار پارامتر حافظه‌ی بلندمدت غیر صفر (و نیز کوچکتر از ۰/۵) و در نتیجه تأییدی بر وجود حافظه‌ی بلندمدت در سری بازدهی بورس می‌باشد. بنابراین، سری بازدهی بورس می‌بایست مجدداً تقاضای‌گیری کسری شده تا بر اساس آن مدل‌سازی صورت پذیرد. که در بخش‌های بعدی به مدل‌سازی سری بازدهی بورس به کمک مدل‌های مبتنی بر حافظه‌ی بلندمدت خواهیم پرداخت.

تخمین مدل ARFIMA به طور کلی روش‌های مختلفی برای برآورد مدل ARFIMA و پارامتر d وجود دارد که عبارتند از: روش دو مرحله‌ای، روش حداکثر درست‌نمایی تقریبی^{۵۷} (AML) و روش حداکثر درست‌نمایی دقیق^{۵۸} (EML)، روش درست‌نمایی تعدیل شده

با توجه به جدول فوق می‌توان نتیجه گرفت که مدل $ARFIMA(1,0.14,2)$ در بین انواع مدل‌های ARFIMA از آماره اطلاعات آکائیک کمتری برخوردار بوده و در نتیجه از بهترین عملکرد برخوردار می‌باشد. که تصریح آن به صورت جدول ۴ می‌باشد.

تخمین مدل ARFIMA

جدول (۴): نتایج تخمین $ARFIMA(1,0.14,2)$

نام متغیر	ضریب	آماره‌ی t	prob
C	۰/۰۰۱۶	۲/۲۱	۰/۰۰۲
d-ARFIMA	۰/۱۴۰۸	۳/۱۳	۰/۰۰۰
AR(1)	-۰/۹۴۰۱	-۳۶/۶	۰/۰۰۰
MA(1)	۱/۲۱۹۶	۱۸/۵	۰/۰۰۰
MA(2)	۰/۲۳۵۸	۳/۸۲	۰/۰۰۰
Dum(1)	۰/۰۳۶۹	۶/۵۸	۰/۰۰۰
Dum(2)	۰/۰۵۲۹	۹/۴۵	۰/۰۰۰
Dum(3)	۰/۰۷۵۸	۱۳/۷	۰/۰۰۰

منبع: یافته‌های محقق

جدول (۵): انواع مختلف مدل‌های ARMA

AIC	\bar{R}^2	Log Likelihood	معیار / مدل
-۷/۳۱۸۲	۰/۳۹	۸۱/۲۹(۰/۰۰۰)	ARIMA(1,1,1)
-۷/۳۲۵۳	۰/۴۰	۶۹/۵۴(۰/۰۰۰)	ARIMA(2,1,1)
-۷/۳۲۸۵	۰/۴۰	۶۹/۹۴(۰/۰۰۰)	* ARIMA(1,2)
-۷/۲۶۶۳	۰/۴۰	۵۹/۷۸(۰/۰۰۰)	ARIMA(2,1,2)

$$\begin{aligned}
 \text{dltd} &= 0.002 + \{0.08\text{DUM}68 + 0.05\text{DUM}101 + \\
 &\quad 0.05\text{DUM}471\} + \dots \\
 t: &(2.74) \quad (21.25) \quad (9.26) \\
 &(10.52) \\
 &+0.91\text{dltd}(-1) - 0.5\text{MA}(1) - 0.29\text{MA}(2) \\
 &(14.74) \quad (-6.12) \quad (-5.23)
 \end{aligned}$$

تخمین مدل NNAR

همانطور که می‌دانیم، نخستین گام در مدل-سازی کلیه مدل‌های غیرخطی مبتنی بر شبکه‌های عصبی، تعیین ترکیب بهینه عوامل طراحی شبکه عصبی با همان « معماری شبکه » می‌باشد. از این-رو، پیش از مقایسه‌ی انواع مختلف مدل‌های NNAR و NNARX، به تبیین معماری شبکه‌ی عصبی سری زمانی پویا می‌پردازیم.

بر اساس معماری شبکه که در جدول ۶ تبیین گردید، به برآورد و مقایسه‌ی انواع مدل‌های مختلف NNAR و NNARX می‌پردازیم.

بر اساس جدول ۷، مدل NNAR(10) (با بکارگیری ده وقفه از سری بازدهی بورس) با توجه به معیارهای R^2 ، MSE و RMSE در بین سایر مدل‌ها از بهترین عملکرد برخوردار بوده است.

لازم به ذکر است که، متغیرهای مجازی معرفی شده در معادله فوق را می‌توان به این صورت تعریف کرد که $Dum(1)$ و $Dum(2)$ مربوط به حوادث بحران مالی ۲۰۰۸ آمریکا (حداقل و حداکثر قیمت) و $Dum(3)$ مربوط به واگذاری سهام شرکت مخابرات ایران در بورس اوراق بهادار در راستای اجرای اصل ۴۴، می‌باشد. همچنین، به منظور درک بهتر کارایی مدل‌های مذکور یک مدل ARIMA نیز به کمک متدولوژی باکس-جنکینز و با استفاده از از برآوردگرهای سازگار وایت^{۶۱} (Robust) برآورد شده است. از این‌رو، بر اساس تعداد دندانه‌های معنادار همبستگی‌نگار^{۶۲}، و نیز بررسی نقاط دور افتاده^{۶۳} - به کمک معرفی آنها به عنوان متغیر مجازی^{۶۴} - جهت افزایش قدرت توضیح دهنده‌ی مدل (افزایش R^2)، مدل‌های ارائه شده در جدول زیر در زمره‌ی بهترین مدل‌های ممکن می‌باشند.

با توجه به جدول فوق مدل $ARIMA(2,1,1)$ از بهترین عملکرد برخوردار بوده است. که فرم تصریحی آن به صورت زیر می‌باشد.

جدول (۶): ترکیب بهینه عوامل طراحی شبکه عصبی (معماری شبکه)

ارزش	عامل طراحی
NNAR & NNARX	نوع شبکه
۱۰	تعداد نرون‌های لایه‌ی پنهان اول
۱	تعداد نرون‌های لایه‌ی پنهان دوم
Feed Forward Network	تابع پیش‌پردازش
LM ^{۶۵}	تابع تبدیل لایه‌ی

منبع: گورسن و همکاران (۲۰۱۱)

جدول (۷): نتایج تخمین انواع مدل‌های NNAR

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

منبع: یافته‌های تحقیق

بنابراین، بر اساس معیارهای ذکر شده به مقایسه‌ی عملکرد دقت مدل‌های این تحقیق در پیش‌بینی خارج از نمونه (۶۰ مشاهده) می‌پردازیم، که نتایج آن در جدول (۸) آورده شده است. نتایج ارائه شده در جدول زیر بیانگر بهتر بودن عملکرد مدل شبکه عصبی پویای NNAR(10) نسبت به مدل ARFIMA (1,0.12,1) در پیش‌بینی سری بازدهی بورس اوراق بهادار تهران طی دوره مورد بررسی می‌باشد.

جدول (۸): نتایج پیش‌بینی مدل‌های ARFIMA و NNAR

مدل‌ها	MSE	RMSE
ARFIMA(1,0.12,1)	۰/۰۰۱۶۰۶	۰/۰۴۰۰۸۲
NNAR(10)	۰/۰۰۰۰۵۲۸	۰/۰۰۷۲۶

منبع: یافته‌های تحقیق

۵- نتیجه‌گیری و بحث

اصولاً یکی از مهمترین نظریه‌های اقتصادی در زمینه‌ی بازارهای مالی، نظریه‌ی پیش‌بینی ناپذیری

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^{۶۶}، ۲۰۱۱).

(۶)

$$MSE = \frac{\sum (\hat{y}_i - y_i)^2}{n}$$

(۷)

$$RMSE = \sqrt{\frac{\sum (\hat{y}_i - y_i)^2}{n}}$$

بینی‌های هرچه دقیق‌تر و نیز بکارگیری سرمایه-گذاران جهت کسب منافع حاصل از اتخاذ تصمیمات سرمایه‌گذاری مناسب به کمک پیش‌بینی-های کاراتر، معرفی نمود.

فهرست منابع

- ۱) بافنده‌ایمان‌دوست، صادق و فهیمی‌فرد، سید محمد و شیرزادی، سمیه، (۱۳۸۸)، "پیش‌بینی نرخ ارز با مدل‌های عصبی-فازی ANFIS، شبکه عصبی خودرگرسیون NNARX و خودرگرسیون ARIMA در اقتصاد ایران (۸۷-۱۳۸۱)"، مجله دانش و توسعه (علمی-پژوهشی)، شماره ۲۸، صفحات ۱۹۲-۱۷۶.
- ۲) 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.
- ۳) حیدری‌زارع، بهزاد و کردلوئی، حمیدرضا (۱۳۸۹)، "پیش‌بینی قیمت سهام با استفاده از شبکه عصبی مصنوعی"، فصلنامه مدیریت، شماره ۱۷.
- ۴) راسخی، سعید و خانعلی‌پور، امیر (۱۳۸۸)، "تحلیل تجربی نوسانات و کارایی اطلاعاتی بازار سهام (مطالعه موردی: بورس اوراق بهادار تهران)"، فصلنامه پژوهش‌های اقتصادی ایران، سال سیزدهم، شماره ۴۰، صفحات ۲۹-۵۷.
- ۵) سلیمی‌فر، مصطفی و شیرزور، زهرا (۱۳۸۹)، "بررسی کارایی اطلاعاتی بازار بورس به

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 قیمت‌ها، روند آتی آنها را با سطح خطای قابل قبولی پیش‌بینی نمود. از جمله‌ی این مدل‌ها می‌توان به مدل‌های غیرخطی شبکه‌ی عصبی و نیز مدل‌های فرکتال 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 شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران (TEDPIX) از مدل‌های غیرخطی شبکه عصبی اتورگرسیون پویا (NNAR) و نیز مدل اتورگرسیون میانگین متحرک انباشته کسری (ARFIMA) استفاده شده است. که نتایج ارائه شده در جدول (۸) نشان می‌دهد که، مدل NNAR پیش‌بینی دقیق‌تری از شاخص بازدهی بورس طی دوره‌ی زمانی مورد بررسی نسبت به مدل ARFIMA دارد. این نتیجه دور از انتظار نبوده، چراکه نتایج تحقیقات پیشین از جمله مطالعه مشیری و مروت (۱۳۸۵) برتری مدل ANN را بر مدل ARFIMA اعلام نموده و همچنین در مطالعات دیگری نظیر بافنده-ایمان‌دوست (۱۳۸۸) به بالاتر بودن دقت مدل‌های شبکه عصبی پویا به نسبت مدل شبکه عصبی مصنوعی اشاره نموده است. در پایان می‌توان استفاده از روش شبکه‌ی عصبی پویا را به عنوان یک روش مناسب جهت استفاده سیاست‌گذاران و تصمیم‌گیران کلان اقتصادی به منظور اعمال پیش-

- روش آزمون نسبت واریانس"، مجله دانش و توسعه، سال هجدهم، شماره ۳۱.
- (۶) عرفانی، علیرضا (۱۳۸۷)، "پیش‌بینی شاخص کل بورس اوراق بهادار تهران با مدل ARFIMA"، پژوهشنامه علوم انسانی و اجتماعی "علوم اقتصادی"، سال هشتم، شماره ۲۸.
- (۷) فلاح‌شمس، میرفیض و دلنوازاصغری، بیتا (۱۳۸۸)، "پیش‌بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی"، مجله فراسوی مدیریت، سال سوم، شماره ۹.
- (۸) فهیمی‌فرد، سید محمد و سالارپور، ماشاء‌الله و صبوحی 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.
- (۹) 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.
- (۱۰) کریمیان، وحید (۱۳۸۷)، "حباب‌های عقلایی با رویکرد هم‌انباشتگی کسری در بازار بورس اوراق بهادار تهران"، پایان نامه کارشناسی ارشد، رشته علوم اقتصادی، دانشگاه تهران.
- (۱۱) کشاورزحداد، غلامرضا و صمدی، باقر (۱۳۸۸)، "برآورد و پیش‌بینی تلاطم بازدهی در بازار سهام تهران و مقایسه دقت روش‌ها در تخمین ارزش در معرض خطر: کاربردی از مدل‌های خانواده FIGARCH"، مجله تحقیقات اقتصادی، شماره ۸۶.
- (۱۲) محمدی، تیمور و طالبلو، رضا (۱۳۸۹)، "پویایی‌های تورم و رابطه تورم و عدم اطمینان اسمی با استفاده از الگوی ARFIMA-GARCH"، پژوهشنامه اقتصادی، سال دهم، شماره اول، صفحات ۱۷۰-۱۳۷.
- (۱۳) مشیری، سعید (۱۳۸۱)، "مروری بر نظریه آشوب و کاربردهای آن در اقتصاد"، فصلنامه پژوهشهای اقتصادی ایران، شماره ۱۲، صفحات ۲۹-۷۱.
- (۱۴) مشیری، سعید و فروتن، فائزه (۱۳۸۳)، "آزمون آشوب و پیش‌بینی قیمت آتی نفت خام"، فصلنامه پژوهشهای اقتصادی ایران، شماره ۲۱، صفحات ۶۷-۹۰.
- (۱۵) مشیری، سعید و مروت، حبیب (۱۳۸۴)، "بررسی وجود فرآیند آشوبی در شاخص بازدهی کل قیمت سهام بازار بورس تهران"، فصلنامه پژوهش‌های اقتصادی ایران، شماره ۲۵، صفحات ۴۷-۶۴.
- (۱۶) مشیری، سعید و مروت، حبیب (۱۳۸۵)، "پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیرخطی"، فصلنامه پژوهشنامه بازرگانی.
- 17) Alagidede, P., (2011), "Return Behavior in Africa's Emerging Equity Markets", The Quarterly Review of Economics and Finance, No. 51, PP. 133-140.
- 18) 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

^{۱۸} همچون الگوهای GARCH، ARFIMA، FIGARCH و الگوهای شبکه‌ی عصبی مصنوعی و فازی و ...

^{۱۹} Xiu & Jin

^{۲۰} Autoregressive

^{۲۱} Moving Average

^{۲۲} Autoregressive Integrated Moving Average

^{۲۳} Mean Equation

^{۲۴} همچنین، از مدل FIGARCH جهت تبیین رفتار «معادله واریانس» استفاده می‌شود.

^{۲۵} به عنوان مثال، ممکن است اطلاعات در خصوص متغیرهای توضیحی، وجود نداشته باشد، همچنین برای پیش‌بینی متغیر وابسته ابتدا باید متغیرهای توضیحی پیش‌بینی شوند که در برخی موارد پیش‌بینی متغیرهای توضیحی امری دشوارتر از متغیر وابسته است (به کمک روش‌های رگرسیون).

^{۲۶} Artificial Neural Network

^{۲۷} Feedback

^{۲۸} Feed forward

^{۲۹} Unite Root

^{۳۰} Cointegration

^{۳۱} Persistence

^{۳۲} Fractional Brownian Motion

^{۳۳} Fractional Integrated Process

^{۳۴} Hurst

^{۳۵} Granger & Joyek

^{۳۶} Hosking

^{۳۷} Dynamic Stationary Process

^{۳۸} Variance Equation

^{۳۹} Fractional Integration

^{۴۰} Auto Correlation Function

^{۴۱} Gewek, Porter-Hudak

^{۴۲} Rescaled Range Analysis

^{۴۳} Modified Rescaled Range

^{۴۴} گفتنی است که به کمک مدل FIGARCH نیز می‌توان به توضیح و مدل‌سازی گشتاور دوم آنها پرداخت.

^{۴۵} Hyperbolic

^{۴۶} Target

^{۴۷} Single Input-Single Output

^{۴۸} Biases

^{۴۹} Gradient Descent with Momentum weight/bias learning function

^{۵۰} Momentum Constant

^{۵۱} Tehran Exchange Dividend Price Index

^{۵۲} Augmented Dickey-fuller

^{۵۳} Phillips-Perron

^{۵۴} Elliott-Rothenberg-Stock

^{۵۵} Kwiatkowski-Phillips-Schmidt-Shin

^{۵۶} Log-Period gram

^{۵۷} Approximate Maximum Likelihood

^{۵۸} Exact Maximum Likelihood

^{۵۹} Modified Profile Likelihood

^{۶۰} Non Linear Least Square

^{۶۱} با توجه به وجود واریانس ناهمسانی در سری مذکور، جهت برآورد معادله میانگینی مناسب که در آن معناداری ضرایب در پرده‌ای از ابهام نباشد، از این روش استفاده شده است.

^{۶۲} Correlogram

^{۶۳} Out Layer

^{۶۴} متغیرهای مجازی معرفی شده در معادله فوق را می‌توان به حوادثی نظیر بحران مالی آمریکا، واگذاری شرکت‌های دولتی به بخش خصوصی (در قالب واگذاری سهام آنها در بورس اوراق بهادار) در راستای اجرای اصل ۴۴، نسبت داد.

^{۶۵} Levenberg-Marquardt

^{۶۶} Swanson, Tayman & Bryan,

Computational Engineering in Systems Applications, Vol. 200585, PP. 412-417.

- 19) Granger, C.W.J & Timmermann, A.(2004)," Efficient market hypothesis and forecasting", International Journal of Forecasting, pages,15–27.
- 20) Granger, C. W. J., Joyeux, R., (1980), "An introduction to long memory time series models and fractional differencing", Journal of Time Series Analysis, No. 1, PP. 15-29.
- 21) Guresen, Erkam & Kayakutlu, Gulgun & Daim, u. Tugrul (2011)," Using artificial neural network models in stock market index prediction", Expert Systems with Applications.
- 22) Hosking, J. R. M. (1981). "Fractional differencing", Biometrika, No. 68, PP. 165-176.
- 23) Kittiakarasakun, J., Tse, Y., (2011), "Modeling the fat tails in Asian stock markets", International Review of Economics and Finance, No. 20, PP. 430–440.
- 24) Swanson, D.A., Tayman, J., Bryan, T.M., (2011), "MAPE-R: a Rescaled Measure of Accuracy
- 25) Xiu, J., Jin, Y., (2007), "Empirical Study of ARFIMA Model Based On Fractional Differencing", Physica-A, No. 377, PP. 137-184

یادداشت‌ها

^۱ Neural Network Auto-Regressive Model (NNAR)

^۲ Auto Regressive Fractional Integrated Moving Average (ARFIMA)

^۳ Mean Square Error

^۴ Root Mean Square Error

^۵ Information Economics

^۶ Long Memory

^۷ در ابتدایی‌ترین شکل این فرضیه بیان می‌شود، همه ما به دنبال پیش‌بینی بازده دارایی‌های مالی هستیم که البته غیر قابل پیش‌بینی می‌باشد.

^۸ Garanjer & Timmermann

^۹ Alagidede

^{۱۰} Kittiakarasakun & Tse

^{۱۱} Fractional Integrated Generalized Autoregressive Conditional Heteroskedasticity

^{۱۲} Gursen & Kayakutlu & Daim

^{۱۳} NASDAQ

^{۱۴} Adaptive Nero Fuzzy Inference System

^{۱۵} Feed Forward Neural Network

^{۱۶} Generalized Autoregressive Conditional Heteroskedasticity

^{۱۷} همانند الگوهای AR، MA، ARIMA و ...