

فصلنامه سیاست‌های مالی و اقتصادی

سال سوم، شماره ۱۲، زمستان ۱۳۹۴، صفحات ۱۴۸-۱۲۵

کاربرد سامانه‌های پویای پارامتری و ناپارامتری در پیش‌بینی بازدهی سهام: مطالعه موردی بازار بورس تهران

سید احسان حسینی دوست

استادیار دانشگاه بوعلی سینا (نویسنده مسئول)

e.hosseinidoust@basu.ac.ir

محمدحسن فطرس

استاد دانشگاه بوعلی سینا

fotros@basu.ac.ir

شراره مساحی

کارشناس ارشد اقتصاد

Shmassahi@yahoo.com

با توجه به نقش بازارهای سرمایه در فرایند تجمیع و توزیع منابع مالی، این بازارها و به‌ویژه بازار بورس همواره مورد توجه سرمایه‌گذاران داخلی و خارجی و دولت‌ها بوده‌اند. از جمله مسائل بازارهای مالی، مسئله ریسک و مدیریت آن است که در بازار بورس این مقوله ارتباط تنگاتنگی با پیش‌بینی قیمت و بازده سهام دارد که اهمیت آن در سنجش کارایی اطلاعاتی بازار منعکس شده است. بر این اساس، پژوهش حاضر به دو روش متفاوت؛ پویاپارامتری با استفاده از مدل نوسانی ARMA-PGARCH و رویکرد پویاناپارامتری با بهره‌گیری از شبکه عصبی خودبازگشتی NARX به مدل‌سازی و پیش‌بینی بازده بورس تهران می‌پردازد. پیش‌بینی‌ها به دو صورت درون‌داده‌ای و برون‌داده‌ای و بر مبنای مشاهدات روزانه طی دوره ۱۳۷۶/۷/۶ تا ۱۳۹۴/۰۳/۰۲ انجام شده است. بر اساس نتایج به‌دست آمده، دقت مدل‌ها در زمینه پیش‌بینی، مقایسه گردیده و همچنین کارایی اطلاعاتی بورس تهران مورد بررسی قرار گرفته است. نتایج پژوهش حاضر نشان‌دهنده عملکرد و کارایی دقیق سامانه پویای ناپارامتریک در مقایسه با رویکرد پارامتریک بوده است. همچنین، یافته‌ها حاکی از عدم کارایی اطلاعاتی بازار بورس تهران در سطح ضعیف آن می‌باشد.

طبقه‌بندی JEL: G11، G14، G17، G32.

واژه‌های کلیدی: مدل‌سازی غیرخطی، روش‌های پارامتریک و ناپارامتریک، پیش‌بینی بازده سهام، کارایی اطلاعاتی بازار بورس.

۱. مقدمه

بهینه‌سازی، از ارکان اصلی علم اقتصاد مالی و مدیریتی مالی است که در بازارهای سرمایه این مسئله در مطلوبیت سرمایه‌گذاری و مدیریت ریسک-بازده منعکس شده‌است. پیش‌بینی دقیق در بازار مالی منجر به کاهش زیان و افزایش سود سرمایه‌گذاری و حداقل‌سازی ریسک (به‌عنوان یک عنصر نامطلوب) می‌گردد که تمام این موارد در نهایت منجر به حداکثرسازی مطلوبیت سرمایه‌گذاری خواهد شد. بازار بورس به‌عنوان یکی از پایه‌های اصلی بازار سرمایه، از قاعده بهینه‌سازی مستثنا نبوده و عرضه‌کنندگان و متقاضیان سرمایه جهت برنامه‌ریزی و مدیریت بهینه منابع مالی و به‌منظور کاهش ریسک سرمایه‌گذاری، همواره در جستجوی روش‌های نوینی برای مدل‌سازی رفتار سری‌های زمانی مالی از قبیل شاخص بازار، قیمت سهام، بازدهی سهام و نسبت‌های مالی بوده‌اند که این مسئله منجر به ظهور رویکردها و تئوری‌های مالی گردیده‌است. اهمیت بازارهای مالی در فضای اقتصادی کشورهای پیشرفته و نقش این بازارها در فرایند توسعه از یک سو و از سوی دیگر پیشرفت‌های صورت گرفته در حوزه‌های مرتبط، از قبیل علوم آمار و کامپیوتر، منجر به ظهور نسل جدیدی از رویکردهای مدل‌سازی گردیده که از توانایی آشکارسازی ویژگی‌های آماری سری‌های زمانی مالی و انعکاس آن‌ها در مدل‌سازی‌ها برخوردار هستند (آپوستولوس، ۱۹۹۵).

در واقع این روش‌های جدید نه تنها توانایی تحلیل و بررسی مواردی از قبیل ایستایی و عدم ایستایی، وجود شکست ساختاری، حضور یا عدم حضور اثر واریانس شرطی را در مدل‌ها ایجاد کردند، بلکه ابعاد جدیدی از پیچیدگی‌های سری‌های زمانی مالی را نیز آشکار ساختند که مدل‌های سنتی پیشین قدرت مناسبی را در منعکس ساختن آن‌ها در مدل‌سازی نداشتند.^۱ نوآوری‌های صورت گرفته در حوزه کامپیوتر و ساخت نرم‌افزارهای قدرتمند منجر به ظهور هوش مصنوعی (AI)^۲ شد که از مشهورترین شاخه‌های آن می‌توان به شبکه‌های عصبی مصنوعی اشاره کرد که الگوبرداری شده از سامانه عصبی بدن انسان هستند. توانایی این الگوریتم‌ها در شناخت الگوهای

۱. از قبیل این موارد می‌توان به وجود پدیده آشوب (Chaos) در سری‌های مالی اشاره کرد که مدل‌های اقتصادسنجی مرسوم قابلیت مناسبی در لحاظ کردن آن ندارند.

پنهان فرایند تولید داده‌ها^۱ و مدل کردن سامانه‌های پیچیده^۲ به حدی بالا بود که جهت مدل کردن و شبیه‌سازی رفتار حرکتی اندام انسان و معرفی آن به ربات‌ها به کار گرفته شدند. امروزه از شبکه‌های عصبی در حوزه‌های گوناگونی از علوم و به‌ویژه در فرایند شبیه‌سازی و پیش‌بینی استفاده می‌شود و دائماً بر ابعاد استفاده از آن افزوده می‌شود. علم اقتصاد مالی نیز از این قاعده مستثنا نبوده و وجود متغیرهای متعدد کمی و کیفی تأثیرگذار بر متغیرهای مالی و پیچیدگی حاکم بر مدلسازی در این حوزه از یک سو و اهمیت و لزوم پردازش سریع و صحیح اطلاعات از سوی دیگر منجر شد تا محققین این حوزه حرکت خود را در جهت به کارگیری رویکردهای هوش مصنوعی از قبیل موتورهای استنتاج فازی،^۳ شبکه‌های عصبی مصنوعی، الگوریتم‌های ژنتیک و سامانه‌های هایبرید آغاز نمایند (شادبولت و تیلور، ۲۰۰۲).

در این میان، با توجه به وجود پدیده آشوب در سری‌های زمانی مالی، وجود واریانس ناهمسان در نوسانات آن‌ها یا رفتار غیرمقارن این متغیرها نسبت به اخبار خوب و اخبار بد، حتی رویکردهای نوین آماری نیز نتوانستند نتایج دلخواه تحلیلگران مالی را به‌ویژه در حوزه‌پیش‌بینی برآورده سازند (اوو و وانگ، ۲۰۱۰).

بر این اساس، پژوهش حاضر با طراحی و به کارگیری شبکه عصبی پویا^۴ NARX به عنوان نماینده‌ای از مدل‌های غیرخطی-ناپارامتریکی و مدل ترکیبی^۵ ARMA-PGARCH به عنوان نماینده‌ای از مدل‌های غیرخطی-پارامتریکی بازدهی شاخص قیمتی بورس تهران (TEPIX) را مدلسازی می‌نماید. وجه مشترک این دو مدل در پویا بودن و غیرخطی بودن آن‌ها است. پس از آن، پیش‌بینی درون‌داده‌ای و برون‌داده‌ای صورت پذیرفته است که نه تنها مقایسه دقت مدل‌های مذکور در فرایند پیش‌بینی را فراهم می‌آورد، بلکه اتخاذ رویکرد مناسب جهت پیش‌بینی بازدهی شاخص بورس تهران را نیز ممکن خواهد ساخت. همچنین، بر اساس نتایج به دست آمده شواهدی را در مورد وجود یا عدم وجود فرم ضعیفی از کارایی اطلاعاتی در این بازار به دست خواهد داد.

1. Hidden Patterns of Data Generation Process
2. Complex Systems Modeling
3. Fuzzy Inference Engine
4. Nonlinear Autoregressive Model Process with Exogenous Input(s)
5. Autoregressive Integrated Moving Average-Power Generalized Autoregressive Conditional Heteroscedasticity Model

بر خلاف بسیاری از مطالعات پیشین که تمرکز اصلی بر روی استفاده از شبکه‌های عصبی استاتیک و مدل‌های پارامتریک خطی ساده بوده‌اند، پژوهش حاضر از مدل عصبی پویا و رویکرد پارامتریک ترکیبی غیرخطی بهره می‌برد که به‌نظر می‌رسد در این حوزه می‌تواند دارای نوآوری باشد.

ساختار پژوهش حاضر به این صورت است که پس از مقدمه، ابتدا مبانی نظری پژوهش به‌اختصار اشاره می‌شوند، سپس مروری اجمالی بر مطالعات پیشین صورت می‌گیرد و با معرفی رویکردهای استفاده شده در مدلسازی، نتایج به‌دست آمده مورد تجزیه و تحلیل قرار می‌گیرند.

۲. مبانی نظری پژوهش

تلاش‌های صورت گرفته جهت تحلیل و پیش‌بینی بازارهای سرمایه باعث به چالش کشیده شدن فرضیه بازارهای کارا گردید که توسط فاما (۱۹۷۰) مطرح شده و بر اساس آن سه سطح از کارایی اطلاعاتی (ضعیف، متوسط و قوی) برای هر بازار سرمایه معرفی گردیده است. در بازاری با سطح ضعیفی از کارایی اطلاعاتی، تمام اطلاعات گذشته یک سهم در قیمت کنونی آن منعکس شده و حرکات قیمت از الگوی گام تصادفی پیروی خواهد کرد، به این معنا که سرمایه‌گذاران نمی‌توانند به‌طور دقیق، قیمت‌های آینده را پیش‌بینی نمایند. فاما بیان می‌دارد که در بازاری با سطح ضعیف کارایی اطلاعاتی، اطلاعات موجود و در دسترس عرضه‌کنندگان و متقاضیان سرمایه از دوره‌های گذشته کمک مفیدی را برای سفته‌بازی بر روی حرکات قیمت در دوره‌های آینده ارائه نمی‌کند. از این‌رو، سطح ضعیف کارایی اطلاعاتی با تئوری گام تصادفی پیوند خورده است؛ زیرا تئوری گام تصادفی بیان می‌دارد که حرکات قیمت یک سهم خاص یا شاخص بازار، غیرقابل پیش‌بینی بوده و از هیچ الگوی مشخصی طی زمان پیروی نمی‌کند. بنابراین، چنانچه ثابت شود که یک بازار از گام تصادفی پیروی می‌کند، می‌توان نتیجه گرفت که سطح ضعیفی از کارایی اطلاعاتی در آن وجود دارد. در سطح متوسط کارایی اطلاعاتی، نه تنها اطلاعات سابق، بلکه اطلاعات عمومی در دسترس در دوره فعلی نیز در تعیین قیمت یک سهم مشارکت داشته‌اند. در نهایت، در بازاری با سطح قوی کارایی اطلاعاتی، علاوه بر اطلاعات عمومی موجود و داده‌های گذشته حتی اطلاعات خصوصی شرکت یا بنگاه اقتصادی نیز در قیمت‌گذاری و نوسانات قیمتی سهام منعکس شده و اثرگذار بوده‌اند (دیک‌من، ۲۰۰۵).

تفاوت بنیادین تئوری‌های مدل‌سازی رفتار متغیرهای بازار سرمایه، در سنگ بنای آن‌ها یا همان فرضیه‌های آن‌ها نهفته است که منجر به بروز تحلیل‌های متفاوت از یک بازار نمونه می‌گردد. بر دیدگاه‌های متداول اقتصادسنجی و برحسب تعداد متغیرهای وارده در مدل می‌توان این تئوری‌ها را به دو گروه کلی مدل‌های تک‌متغیره و مدل‌های چندمتغیره طبقه‌بندی نمود. اساس مدل‌های چندمتغیره (از قبیل: APT^1 ، $CAPM^2$ و RW^3) بر این فرض استوار است که رفتار قیمت و به‌ویژه بازدهی یک سهم صرفاً تحت تأثیر متغیرهای بازار سرمایه نبوده بلکه تابعی از دیگر متغیرهای تأثیرگذار نیز می‌باشد و در مدل‌سازی‌ها باید فاکتورهای کلان اقتصادی همچون نرخ ارز، تورم، GDP، قیمت طلا، قیمت نفت و مانند آن‌ها و متغیرهای خرد اقتصادی همچون BV ، B/M ، EPS ، P/E و نظایر آن‌ها نیز در نظر گرفته شوند. در مدل‌های تک‌متغیره، اساس تحلیل‌ها بر این فرض استوار است که تمام اطلاعات مورد نیاز جهت تحلیل رفتار یک متغیر، در سری‌زمانی مربوط به آن نهفته است و تاریخ ماهیتی تکرار شونده دارد. بنابراین، با تحلیل سری‌زمانی قیمت یا بازدهی یک سهم، توانایی تحلیل رفتار آن در آینده نیز میسر خواهد بود. بر این اساس، مدل‌سازی تک‌متغیره را می‌توان تحت تحلیل‌های تکنیکال و مدل‌سازی چندمتغیره را تحت تحلیل‌های بنیادین طبقه‌بندی نمود (شادبولت و تیلور، ۲۰۰۲).

۳. پیشینه مطالعاتی

بر اساس اطلاعات موجود، به کارگیری شبکه‌های عصبی مصنوعی به منظور پیش‌بینی بازار بورس برای نخستین بار توسط وایت (۱۹۹۸) صورت پذیرفته که با استفاده از شبکه استاتیک (FFNN)^۴ اقدام به پیش‌بینی قیمت روزانه سهام شرکت IBM کرده است. نتایج این تحقیق بیانگر کارایی مناسب این شبکه در شبیه‌سازی الگوی غیرخطی موجود در حرکات قیمت سهام می‌باشد. در سال‌های اخیر نیز شمس‌الدین و همکاران (۲۰۰۸) طی یک مطالعه مقایسه‌ای بر روی مشاهدات ماهانه دوره (۱۹۹۰-۲۰۰۴) اقدام به بررسی کارایی این شبکه‌ها با استفاده از توپولوژی‌های متفاوت و

1. Arbitrage Pricing Theory
2. Capital Assets Pricing Model
3. Random Walk
4. Feed-Forward Neural Network

بهره‌گیری از توابع فعال‌ساز^۱ مختلف نموده‌اند که جهت مقایسه دقت پیش‌بینی این شبکه‌ها، معیارهای MAPE و RMSE به کار گرفته شده‌اند و نتایج تحقیق به روشنی نشانگر قابلیت چشمگیر این سامانه‌ها در دستیابی به الگوهای غیرخطی پنهان در سری‌های زمانی بازار بورس است. آوچی (۲۰۰۹) طی تحقیق بر روی بازدهی سهام سه شرکت فعال در بورس استانبول و همچنین شاخص کل بازار (ISE-300) طی سال‌های (۲۰۰۷-۲۰۰۸) ثابت کرده است که مدل‌هایی عصبی با الگوریتم تصحیح خطای BP^۲ در پیش‌بینی و انتخاب بهینه سهام شرکت‌ها، با تمام دیگر مدل‌های رقیب و دیگر استراتژی‌های معامله از قبیل Buy-and-Hold به خوبی رقابت کرده و نتایج کارتری را به دست داده‌اند. کلسن (۲۰۰۵) با به کارگیری شبکه عصبی استاتیک (FFNN) با الگوریتم تصحیح خطای لونیبرگ-مارکوات (LM) اقدام به پیش‌بینی روزانه شاخص قیمت NASDAQ و شاخص قیمت Dow-Jones در دوره زمانی (۲۰۰۲-۲۰۰۵) نموده است. نتایج این تحقیق نشانگر عملکرد کارای این سامانه در پیش‌بینی شاخص‌های قیمت مذکور است.

ماسیل و بالینی (۲۰۰۸) پا را فراتر نهاده و به مطالعه بر روی شاخص‌های شناخته شده بازارهای بورس جهان از قبیل: S&P500، CAC40، FTSE، DAX، Dow-Jones، IBEX35 و PS120 پرداخته‌اند که در این مورد از شبکه عصبی مصنوعی (FFNN) با الگوریتم تصحیح خطای (LM) بهره برده‌اند و جهت برآورد دقت پیش‌بینی‌ها از معیارهایی همچون MSPE، $RMSE \cdot R^2$ و MSE استفاده کرده‌اند؛ یافته‌ها بیانگر آن است که این سامانه در پیش‌بینی شاخص بازارهای بورس دقت و سرعت بسیار مناسبی را دارد.

با نگاهی به تاریخچه شبکه‌های عصبی پویا و کاربردی شدن آن‌ها در حوزه اقتصاد مالی، مشخص می‌شود که در مقایسه با دیگر تکنیک‌های پیش‌بینی سری‌های زمانی، این روش رویکردی تازه در حوزه پیش‌بینی بازارهای سرمایه محسوب می‌گردد. در زمینه کاربرد شبکه‌های پویا در پیش‌بینی بازار بورس، وانگ و لیو (۱۹۹۴) با استفاده از شبکه پویا بر پایه مدل ARMA و با به کارگیری داده‌های روزانه شاخص وزنی بورس تایوان (TSEWI) طی سال‌های (۱۹۹۱-۱۹۹۴) اقدام به پیش‌بینی وضعیت بازار کرده‌اند که نتایج حاصله بیانگر عملکرد کارای این شبکه در فرایند پیش‌بینی می‌باشد.

1. Activation Functions
2. Back-Propagation

دیاکونسکو (۲۰۰۸) با به‌کارگیری و طراحی یک شبکه پویا NARX به مطالعه بر روی شاخص BET در بازار بورس کشور رومانی پرداخته است و از دو معیار MSE_reg و MSE جهت برآورد دقت پیش‌بینی استفاده شده و دوره زمانی انتخاب‌شده دربرگیرنده مشاهدات روزانه سال‌های (۲۰۰۵-۲۰۰۸) است. نتایج این تحقیق نشان‌دهنده پتانسیل بالای این شبکه در کشف مسیر حرکت غیرخطی قیمت سهام می‌باشد. محقق بیان داشته که معماری یا توپولوژی انتخاب‌شده تأثیر حائز اهمیتی بر قدرت پیش‌بینی این شبکه‌ها و نتایج حاصله دارد و رفتار این شبکه به شدت وابسته به بُعد حافظه تعبیه‌شده، تعداد لایه‌های شبکه و تعداد نرون‌های^۱ انتخابی دارد.

برخلاف شبکه‌های عصبی استاتیک که حجم قابل توجهی از مطالعات را در حوزه اقتصاد مالی و بازارهای مالی و به‌ویژه در پیش‌بینی بازار بورس و قیمت سهام به خود اختصاص داده‌اند، در مورد شبکه‌های عصبی پویا و کاربرد آن‌ها، به‌طور نسبی مطالعات کمتری انجام شده است که این مسئله به دشوار بودن برنامه‌نویسی برای این نوع از شبکه‌های عصبی بازمی‌گردد.

منجمی، ابزری و رعیتی (۱۳۸۸) طی پژوهشی تحت عنوان "پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی-فازی و الگوریتم ژنتیک و مقایسه آن با شبکه عصبی مصنوعی" بیان می‌دارد که معماری شبکه بر عملکرد شبکه تأثیرگذار است اما استفاده از لایه‌های مخفی بیشتر لزوماً منجر به بهبود عملکرد شبکه نمی‌شود و با افزایش تعداد نرون‌های لایه‌های پنهان نمی‌توان انتظار داشت که عملکرد شبکه بهبود پیدا کند. همچنین، مقایسه نتایج حاصل از مدل شبکه عصبی با نتایج حاصل از مدل عصبی-فازی و الگوریتم ژنتیک نشان می‌دهد که از نقطه‌نظر معیارهای ارزیابی عملکرد پیش‌بینی، شبکه عصبی-فازی و الگوریتم ژنتیک، خطای پیش‌بینی قیمت سهام را نسبت به روش شبکه عصبی کاهش می‌دهند.

۴. داده‌ها و روش پژوهش

تمرکز تحقیق حاضر بر بازده شاخص اصلی بورس تهران (TEPIX) بوده که شاخص قیمت، از وب‌سایت رسمی بورس تهران^۲ استخراج شده و دربرگیرنده مشاهدات روزانه شاخص کل در

1. Neurons

2. WWW. IR Bourse. com

دوره زمانی ۱۳۷۶/۷/۶ تا ۱۳۹۴/۳/۲ می‌باشند و بیانگر ارزش شاخص در پایان روز کاری و بسته‌شدن بازار است. بازدهی شاخص از طریق رابطه (۱) محاسبه می‌گردد:

$$R_t = \ln \left(\frac{p_t}{p_{t-1}} \right) \quad (1)$$

که در آن R_t نشان‌دهنده بازدهی در زمان t بیانگر قیمت شاخص در زمان t می‌باشد. مدل نخست پژوهش حاضر، ترکیبی از مدل پویا ARMA و مدل نوسانی PGARCH است که قابلیت مدل کردن رفتار سری زمانی واریانس شرطی و رفتار سری زمانی میانگین را به صورت همزمان دارد. مدل PGARCH در میان دیگر مدل‌های نوسانی همواره عملکرد مناسبی را از خود نشان داده است که این مسئله ناشی از عدم تحمیل محدودیت در مدل کردن واریانس شرطی است (فرانسیس و فن‌دیک، ۱۹۹۶).

از سوی دیگر، مدل ARMA یا روش باکس-جنکینز نیز جزو شناخته‌شده‌ترین رویکردهای تحلیل رفتار میانگین در بازارهای مالی محسوب می‌گردند که فرم عموم این مدل در رابطه (۲) نمایش داده شده است:

$$Y_t = \theta + \sum_{i=1}^p \eta_i Y_{t-i} + \sum_{j=1}^q \lambda_j u_{t-j} \quad (2)$$

در آن، Y_t نشانگر ارزش متغیر در دوره جاری، Y_{t-i} نشان‌دهنده ارزش متغیر در i دوره گذشته، u بیانگر ارزش جمله پسماند و θ, η, λ پارامترهای معادله هستند. مدل PGARCH توسط دینگ، انگل و گرنجر (۱۹۹۳) معرفی گردیده که بر اساس آن، واریانس شرطی صورت رابطه (۳) تعریف می‌گردد:

$$\sigma_t^\delta = \omega + \sum_{i=1}^p \alpha_i \left(|\varepsilon_{t-i}| - \gamma \varepsilon_{t-i} \right)^\delta + \sum_{j=1}^q \beta_j \sigma_{t-j}^\delta \quad (3)$$

که در آن ضریب سیگما (γ) تعیین‌کننده وجود یا عدم وجود رفتار متقارن شاخص قیمت می‌باشد. متغیر فرض کردن توان سیگما، انعطاف‌پذیری بیشتری را در برازش داده‌ها به مدل خواهد داد و در نتیجه کارایی بالاتر این مدل را در مقایسه با مدل اولیه GARCH انتظار داریم.

دلیل انتخاب مدل ARMA-PGARCH این است که این مدل ترکیبی جزو مدل‌های پیش‌بینی تک‌متغیره‌ای بوده که کارایی مناسبی را در پیش‌بینی از خود نشان داده است و حتی از مدل‌های ترکیبی EGARCH ARMA- و ARMA-TGARCH نیز در مواردی عملکرد کاراتری را از خود نشان می‌دهد که این مسئله در تحقیقات دیگر محققین این حوزه نیز مورد تأیید واقع شده است (لیو و همکاران، ۲۰۰۹؛ چن و کیمیلیان، ۲۰۰۵). جهت تست ایستایی شاخص قیمت و بازدهی آن، از تست زیوت-اندروز (۱۹۹۲) و آزمون دیکی-فولر ارتقایافته استفاده شده است. مزیت آزمون زیوت-اندروز در مقایسه با سایر تست‌های ایستایی در توانایی تشخیص وجود شکست ساختاری و همچنین بررسی ایستایی در صورت وجود شکست در آن است.


مدل دوم پژوهش، شبکه‌عصبی مصنوعی NARX است که جزو سامانه‌های عصبی دینامیک طبقه‌بندی شده و آن‌را شبکه‌ای بر مبنای مدل ARMA نیز نامیده‌اند.^۱ سامانه‌های شبکه‌عصبی عموماً ذیل روش‌های ناپارامتریک طبقه‌بندی شده‌اند و برخلاف متدهای پارامتریک، هیچ معادله مشخصی را به عنوان تابع رفتاری متغیرها به دست نمی‌دهند و از این رو به آن‌ها لقب جعبه سیاه داده‌اند (چن و همکاران، ۱۹۹۰).

شبکه‌های عصبی به دو گروه کلی استاتیک و دینامیک تقسیم می‌گردند که شبکه‌های استاتیکی عموماً برای شبیه‌سازی داده‌هایی که نویز پایینی دارند یا پروسه تولید آن‌ها دارای فرم خودبازگشتی نبوده مناسب است و چنانچه درست طراحی گردند از سرعت آموزش بالایی برخوردار هستند (مک‌کای، ۲۰۰۴).

ساختار یک شبکه عصبی دینامیک در نمودار (۱) نمایش داده شده است. شبکه‌های پویا به دلیل ساختار پیچیده‌تری که دارند از سرعت آموزش پایین‌تری برخوردار هستند و برای شبیه‌سازی داده‌های پرنوسان یا دارای ساختاری خودبازگشتی مناسب هستند (نارندرا و پارتاساراتی، ۱۹۹۰). فرم عمومی این رویکرد با فرض وجود ابعاد متناهی برای آن با ابعاد (n, m) و ضرایب اسکالر y و u به صورت زیر خواهد بود (لین و همکاران، ۲۰۰۹):

$$y_t = \phi(y_{t-1}, \dots, y_{t-n}, u_{t-1}, \dots, u_{t-m}) \quad (4)$$

که در آن، y_{t-i} و u_{t-i} به ترتیب بیانگر بخش خودبازگشتی (AR) و میانگین متحرک (MA) برای ورودی‌های برونزای سیستم و y_t خروجی این سامانه است. همچنین (Φ) یک تابع فعال‌ساز غیرخطی مانند تابع سیگموئید یا تانژانت هایپربولیک است.



مأخذ: www.Mathwork.com.

نمودار ۱. ساختار عمومی شبکه NARX

با توجه به نمودار (۱)، فرم کلی معادله یا همان الگوریتمی که پیش‌بینی‌ها از آن حاصل می‌گردند از مشاهدات $u(k), u(k-1), \dots, u(k-d_u)$ و همچنین از مقادیر $y(k), y(k-1), \dots, y(k-d_y)$ به‌عنوان ورودی استفاده می‌کند (یانگ و منگ، ۲۰۱۱) که در رابطه (۴) معرفی شده‌اند.

$$y(k+1) = \Phi_0 \left\{ w_{h0} + \sum_{h=1}^N w_{h0} * \Phi_h \left(w_{h0} + \sum_{i=0}^{d_u} w_{ih} * u(k-i) + \sum_{j=0}^{d_y} w_{jh} * y(k-j) \right) \right\} \quad (5)$$

در آن، d_u و d_v به ترتیب بیانگر درجه تأخیر لحاظ شده در ورودی و خروجی سامانه می‌باشند.^۱


۵. یافته‌های پژوهش

روند شاخص کل قیمت بورس تهران و بازدهی آن در نمودار (۲) ترسیم شده و آمار توصیفی داده‌های گردآوری شده، در جدول (۱) خلاصه شده‌اند:

جدول ۱. آمارتوصیفی سری زمانی شاخص بورس تهران و بازدهی آن

سری زمانی	کشیدگی	چولگی	انحراف استاندارد	حداقل	حداکثر	میانه	میانگین
شاخص قیمت	۵/۵۴۴۹۵۱	۱/۸۹۷۱۲۰	۲۱۰۰۴/۰۹	۱۴۷۲	۸۹۵۰۰/۶۰	۱۰۰۷۶/۰۱	۱۷۵۸۴/۸۳
بازدهی	۱۴/۲۹۸۷۵	۰/۲۴۵۷۷۶	۰/۰۰۵۹۵۲	-۰/۰۵۶۷۰۳	۰/۰۵۲۶۰۸	۰/۰۰۰۵۸۱	۰/۰۰۰۸۷۴

مأخذ: نتایج تحقیق.



نمودار ۲. سری زمانی قیمت (Price) و بازده (Return)

۱. برای آشنایی بیشتر با شبکه‌های عصبی مصنوعی دینامیک به کتاب ندنویسکی ۲۰۰۲ و مقاله لین و همکاران (۱۹۹۶) مراجعه نمایید.

همچنین، در جدول (۲) نتایج آزمون ایستایی زیووت-اندروز و دیکی-فولر ارتقایافته بر روی سری قیمت و سری بازده با دربرگیری جداگانه و همزمان عرض از مبدأ و شیب در معادله مربوطه خلاصه شده‌اند:

جدول ۲. نتایج آزمون‌های ایستایی

نوع آزمون	تست بر روی سری بازده		تست بر روی سری قیمت	
	با روند و عرض از مبدأ	با عرض از مبدأ	با روند و عرض از مبدأ	با عرض از مبدأ
دیکی فولر ارتقایافته	-۹/۶۳۱۲***	۹/۶۳۷۱***	-۰/۲۱۳۶	۱/۵۳۵۹
زیووت-اندروز	-۱۹/۶۵۸۵***	-۱۹/۶۴۵۸***	-۲/۶۷۱۱	-۰/۲۳۱۱

تذکر: ***، **، * به ترتیب به معنای معنادار بودن ضریب در سطح معنادار ۱ درصد، ۵ درصد و ۱۰ درصد می‌باشند
مأخذ: نتایج تحقیق.

مقادیر برآورد شده بیانگر عدم ایستایی سری قیمت و ایستایی سری بازده شاخص بورس تهران در سطح اطمینان ۱ درصد هستند؛ براین اساس جهت مدلسازی و پیش‌بینی توسط رویکرد پارامتریک، متغیر بازده بورس تهران به عنوان متغیر ورودی مورد استفاده قرار می‌گیرد. به علاوه، با توجه به قابلیت تخمین تاریخ شکست در آزمون زیووت-اندروز، تاریخ‌های ۱۳۹۴/۹/۲ و ۱۳۹۲/۱۰/۱۵ برای سری شاخص قیمت کل و ۱۳۸۲/۰۵/۱۴ و ۱۳۹۱/۵/۱۶ برای سری بازده به عنوان تاریخ‌های وقوع شکست ساختاری در سری‌های مذکور برآورد شده است که بر اساس اطلاعات و اخبار موجود درباره بازار بورس تهران، تاریخ‌های برآورد شده قابل قبول هستند.

پس از تست ایستایی و با اجرای مدل‌های گوناگونی از ترکیبات متفاوت مدل آرما و مدل نوسانی پی‌گارچ، در نهایت مدل ترکیبی $ARMA(2,1)-PGARCH(2,2)$ به عنوان مدل نهایی مورد استفاده قرار گرفته است که با توجه به نتایج حاصله از تست‌های تشخیص خودهمبستگی از طریق آزمون Ljung-Box و همچنین ناهمسانی واریانس توسط آزمون ARCH-Heteroscedasticity، مشخص گردید که مدل مورد استفاده مدل صحیح بوده و قابلیت به کارگیری برای پروسه پیش‌بینی را دارد. نتایج آزمون‌های مذکور در جدول (۳) خلاصه شده‌اند:

جدول ۳. نتایج آزمون‌های تشخیص صحت مدل ARMA(2,1)-PGARCH(2,2)

نام آزمون	آماره-F	آماره-Q ²	آماره-Q
خودهمبستگی سریالی لیونگ-باکس	-	۱۰/۱۵۳۸	۲۶/۶۳۸۲
ناهمسانی واریانس-آرچ	۰/۸۵۵۶	-	-

مأخذ: نتایج تحقیق.

نتیجه آزمون همبستگی سریالی که تا ۱۵ دوره وقفه در آن لحاظ شده است، حاکی از عدم وجود مشکل خودهمبستگی در جمله خطا می‌باشد. همچنین نتیجه تست ARCH نیز نشانگر عدم وجود ناهمسانی در واریانس جمله خطا است و در مجموع می‌توان نتیجه گرفت که این مدل از لحاظ آماری مورد تأیید بوده و مدل مناسبی جهت پیش‌بینی است. نتایج حاصله از اجرای این مدل در پیوست (۱) و مقادیر پیش‌بینی شده در نمودار پیوست (۲) آمده است. در گام بعدی و با توجه به پذیرفته شدن مدل از نظر آماری، پیش‌بینی درون داده‌ای و برون داده‌ای صورت پذیرفته است که برای پیش‌بینی برون داده‌ای افق زمانی کوتاه مدت پنج روزه در نظر گرفته شده که دلیل این انتخاب سرعت بالای معاملات در بازار بورس و جابه جایی سریع سرمایه بوده است.

پیش از بیان نتایج مدل شبکه NARX ذکر این مسئله ضروری است که شبکه‌های عصبی برخلاف سامانه‌های پارامتریک که روش‌هایی مدل-ران^۱ هستند، جزو سامانه‌های داده-ران^۲ طبقه‌بندی می‌شوند؛ به این معنا که در این حالت، مدل آماری جهت انجام تست‌های تشخیص بر روی آن وجود ندارد و محققین باید از رویکردهایی همچون چگالی کرنل، رسم کوانتایل یا نحوه توزیع احتمال داده‌ها بهره‌گیری نمایند (دیک‌من، ۲۰۰۵). خصوصیات شبکه طراحی شده در جدول (۴) خلاصه شده است که دربرگیرنده پارامترهای مختلف آموزش این شبکه می‌باشد:


جدول ۴. ویژگی‌های سیستمی شبکه

الگوریتم آموزش	سیگنال‌های تأخیر	تابع خطای شبکه	تعداد تکرار	تابع فعال‌ساز	نوع شبکه
BP	۱۰	MSE	۱۰۰	Sigmoid	NARX(SP)

مأخذ: نتایج تحقیق.

1. Model-Driven Methods
2. Data-Driven Methods

لازم به ذکر است که متغیر ورودی، پیش از ورود به شبکه نرمال‌سازی شده و در بازه صفر و یک قرار گرفته است. شبکه، وزن‌هایی را به صورت تصادفی در ابتدای کار در نظر گرفته و سپس با استفاده از الگوریتم تصحیح خطای BP وزن‌ها را به گونه‌ای اصلاح کرده است که پس از اتمام آموزش و رسیدن به سطح خطای مورد نظر، سیگنال شبیه‌سازی شده منطبق بر سیگنال ورودی شده باشد. باتوجه به نمودار (۳)، عملکرد مناسب شبکه طراحی شده در تشخیص نوسانات سری زمانی بازده بورس تهران مشاهده می‌شود. جهت بررسی صحت این سامانه، از آزمون تابع توزیع احتمالی داده‌ها و آزمون کوانتایل بهره برده‌ایم. آزمون توزیع احتمالی داده‌ها یک برآوردکننده مناسب از نوع تابع توزیع داده‌ها است که در تحقیق حاضر به عنوان ابزاری جهت تست تشابه تابع توزیع ورودی شبکه عصبی (سری بازده شاخص بورس تهران) و مقادیر شبیه‌سازی شده توسط شبکه NARX به کار گرفته شده و نتایج حاصله در پیوست (۳) نمایش داده شده است. رسم تابع احتمالی توزیع بازده بورس تهران در قسمت D و خروجی شبکه عصبی در قسمت E آورده شده‌اند. از یک سو با توجه به این نکته که دامنه و برد هردو تابع در محورهای x و y مقادیری یکسان هستند و از سوی دیگر با در نظر گرفتن تشابه بسیار زیاد تابع توزیع احتمال خروجی شبکه عصبی با تابع توزیع احتمالی بازدهی بورس تهران، می‌توان نتیجه گرفت که شبکه عصبی با موفقیت پروسه تولید داده‌ها را تشخیص داده و در نتیجه، تابع توزیع احتمالی خروجی‌ها، منطبق با تابع توزیع احتمال ورودی‌های آن به دست آمده است.



نمودار ۳. قابلیت شبکه NARX در شناخت الگوی سری زمانی

در نهایت، از رسم کوانتایل نیز برای هر دو سری بهره گرفته شد تا در کنار آزمون قبل، صحت پروسه شبیه‌سازی تضمین شده باشد. رسم کوانتایل در واقع روش جایگزین برای تست تابع چگالی احتمال توزیع (PDF)^۱ و تابع توزیع تراکمی (CDF)^۲ است که نتیجه آن در پیوست (۴) آورده شده است. رسم تابع کوانتایل بازده بورس تهران در قسمت F و خروجی شبکه عصبی در قسمت G آورده شده‌اند. همانند نمودارهای توزیع احتمال داده‌ها، در اینجا نیز با مقایسه مقادیر محورهای افقی و عمودی دو نمودار، یکسان بودن نحوه توزیع هردو سری اثبات می‌شود و نه تنها در میانه توزیع، بلکه در انتهای هردو سمت توزیع در دنباله‌های چپ و راست نیز شبکه طراحی شده در شناخت و پیاده‌سازی الگوی سری زمانی عملکرد بسیار مناسبی را دارا بوده‌اند. بنابراین، تابع توزیع سری زمانی اصلی و سری زمانی شبیه‌سازی شده توسط شبکه عصبی، کاملاً یکسان بوده و شبکه عصبی طراحی شده کارایی مناسبی در شناخت الگوی توزیع داده‌ها داشته است. در گام نهایی، پیش‌بینی برون‌داده‌ای هردو مدل تحقیق صورت گرفته که مقادیر آن‌ها در پیوست (۵) گزارش شده است. جهت برآورد دقت پیش‌بینی‌ها از ۸ معیار گوناگون استفاده شده که عبارتند از:

- معیار مربع خطا (MSE)
 - میانگین قدر مطلق خطا (MAE)
 - مجذور میانگین قدر مطلق خطا (RMSE)
 - میانگین درصد قدر مطلق خطا (MAPE)
 - آماره u آزمون تیل (Theil's U-statistic)
 - نسبت تورش (Bias Proportion)
 - نسبت واریانس (Variance Proportion)
 - نسبت کوواریانس (Covariance Proportion).
- نتایج حاصله در جدول (۵) به صورت زیر گردآوری شده‌اند:

جدول ۵. مقایسه دقت مدل‌ها بر اساس معیارهای خطا


معیارهای سنجش خطا	مدل پارامتریک (ARMA-PGARCH)		مدل غیر پارامتریک (NARX)	
	نوع پیش‌بینی			
	درون‌داده‌ای	برون‌داده‌ای	درون‌داده‌ای	برون‌داده‌ای
MSE	۲/۶*E-۵	۲/۷*E-۴	۷/۷۱*E-۱۲	۳/۳۵*E-۵
RMSE	۰/۰۰۵۱	۰/۰۱۴۳	۲/۷۴*E-۶	۰/۰۰۵۷
MAE	۰/۰۰۳۱	۰/۰۱۳۳	۲/۵۱*E-۶	۰/۰۰۳۷
MAPE	۱۵۱/۰۴۳۳	۱۰۱/۳۴۱۷	۶/۱۶*E-۹	۴/۴۵۵۴
Theil's U-Statistic	۰/۸۹۴۸	۰/۹۷۳۸	۶/۹۲*E-۴	۰/۱۱۰۲
Bias Proportion (BP)	۰/۰۰۳۶	۰/۲۲۳۴	۳/۱۲*E-۴	۰/۱۰۹۱
Variance Proportion (VP)	۰/۹۷۸۴	۰/۷۷۰۲	۴/۲۶*E-۵	۰/۶۱۸۳
Covariance Proportion (CP)	۰/۰۱۷۲	۰/۰۰۶۳	۲/۱۸*E-۵	۰/۰۰۰۲

تذکر: $E-\alpha$ نشانگر ۱۰ به توان منفی α است.

مأخذ: نتایج تحقیق.

پیش از تفسیر نتایج این جدول لازم به ذکر است که هرچه مقادیر برآوردشده معیارهای خطا کمتر باشند، نشان‌دهنده مدل مناسب‌تر و قدرت پیش‌بینی بالاتر آن خواهند بود؛ بر این اساس طبق معیار MSE میزان میانگین مربع خطای برآوردشده مدل پارامتریک هم در پیش‌بینی درون‌داده‌ای و هم در پیش‌بینی برون‌داده‌ای در مقایسه با مدل ناپارامتریک، بالاتر بوده که بیانگر دقت بالاتر مدل شبکه عصبی در شناخت الگوی سری‌زمانی و برازش مناسب‌تر داده‌ها است؛ به‌ویژه، سطح $7/71 \times 10^{-12}$ حاکی از قدرت بسیار بالای این مدل در تشخیص شیوه و نحوه فرایند ایجادکننده این سری‌زمانی می‌باشد. مشابه این مسئله هنگام به کارگیری دیگر معیارهای خطا نیز اتفاق می‌افتد، به این معنا که سطح خطای برآوردشده توسط معیارهای RMSE، MAE، MAPE، Theil's U، BP، VP و CP برای سامانه شبکه‌عصبی NARX بسیار پایین‌تر از مدل ترکیبی پارامتریک پژوهش بوده است که بیانگر دقت بسیار بالای این سامانه در شناخت الگوی سیگنال ورودی دارد. در مورد پیش‌بینی برون‌داده‌ای نیز نتایج مشابه به‌دست آمده است و معمولاً سامانه‌ها یا مدل‌هایی که در پیش‌بینی درون‌داده‌ای موفق‌تر عمل می‌کنند در پیش‌بینی برون‌داده‌ای نیز عملکرد بهتری دارند. بر اساس معیارهای خطای VP و CP، مدل ترکیبی آرما توانسته است کارایی بالاتری را

نسبت به سامانه عصبی از خود نشان دهد و شبکه عصبی نتوانسته برتری خود را حفظ نماید. واریانس شاخصی جهت نمایش میزان پراکندگی از میانگین است، بنابراین پایین تر بودن معیار خطای VP در مدل ترکیبی بیانگر این واقعیت است که واریانس مقادیر پیش‌بینی شده توسط مدل پارامتریک تحقیق به واریانس مقادیر حقیقی نزدیک تر بوده است. این در حالی است که بر اساس معیار BP که نشانگر میزان انحراف از میانگین است، مقادیر پیش‌بینی شده شبکه عصبی به میانگین مقادیر حقیقی بازده نزدیک تر بوده‌اند. همچنین، معیار CP بیانگر سطح خطای غیرقابل توضیح این سامانه‌ها می‌باشد که بر اساس آن رویکرد عصبی سطح خطای بالاتری را نشان داده است. از جمله دلایل این مسئله می‌توان به ماهیت ناپارامتریک شبکه‌های عصبی^۱ و همچنین وابستگی شدید نتایج حاصله از این سامانه‌ها به داده‌های ورودی از یک سو و وزن‌هایی که سامانه در ابتدا به صورت تصادفی در حلقه‌های اتصال سلول‌ها در نظر می‌گیرد، اشاره کرد. نتیجه پیش‌بینی برون داده‌ای هر دو مدل به همراه مقادیر واقعی بازده شاخص بورس تهران در نمودار (۴) آورده شده‌اند.



نمودار ۴. مقادیر پیش‌بینی شده توسط مدل ARMA-PGARCH و شبکه عصبی NARX

۱. به این معنا که آنها درصدد مدل کردن سری زمانی جهت یافتن معادله رگرسیون فرایند تولید داده‌ها نیستند و صرفاً به دنبال ایجاد ساختاری براساس ورودی‌های سیستم هستند.

جهت جمع‌بندی، می‌توان بیان داشت که شبکه عصبی NARX بر اساس معیارهای خطای معرفی شده در این پژوهش توانسته است عملکرد کارتری را در مقایسه با مدل ترکیبی ARMA-PGARCH در تشخیص و شبیه‌سازی فرایند تولید داده‌ها از خود نشان دهد و اگرچه در پیش‌بینی برون-داده‌ای بر اساس معیارهای خطای VP و CP عملکرد ضعیف‌تری داشته، اما بر اساس ۶ معیار دیگر توانسته است نسبت به مدل پارامتریک تحقیق عملکرد مناسب‌تری داشته باشد و کارایی و دقت قابل قبولی در پیش‌بینی از خود نشان بدهد. در مجموع و با توجه به نتایج به‌دست آمده از هردو مدل تحقیق، در مورد کارایی اطلاعاتی بازار بورس تهران و بازدهی شاخص TEPIX می‌توان چنین نتیجه گرفت که پژوهش حاضر شواهدی را مبنی بر عدم وجود سطح ضعیف کارایی اطلاعاتی در این بازار ارائه کرده است که این یافته با نتایج دیگر محققین در مورد این بازار همخوانی دارد (به‌عنوان مثال نگاه کنید به: مشیری و مروت، ۱۳۸۵؛ سینایی و دیگران، ۱۳۸۴؛ مهرآرا و عبدلی، ۱۳۸۷؛ عباسیان و حسینی‌دوست، ۱۳۹۲).

۶. خلاصه و نتیجه‌گیری

اهمیت بازارهای سرمایه و به‌ویژه بازار بورس در فرایند توسعه کشورها و نقش این بازارها در جمع‌آوری سرمایه‌های خرد و گسترش مالکیت‌های خصوصی و فراهم کردن بستری مناسب برای توسعه سرمایه‌گذاری‌ها، باعث شده تا این بازارها همواره مورد توجه محققین اقتصاد مالی و مدیریت مالی باشند. مسئله‌ای که بحث‌های زیادی را ایجاد کرده مسئله کارایی این بازارها و به‌ویژه کارایی اطلاعاتی آن‌ها است که پیوند ناگسستنی با تئوری گام تصادفی و مقوله پیش‌بینی بازار برقرار کرده است. همچنین، رشد و گسترش روش‌های هوش مصنوعی و به‌ویژه شبکه‌های عصبی مصنوعی باعث شد تا یکی از کاربردهای این رویکرد که در مسئله پیش‌بینی می‌باشد، در تحقیق حاضر به کار گرفته شود. در این زمینه برخلاف پژوهش‌های پیشین که اغلب مبتنی بر شبکه‌های عصبی استاتیک بوده‌اند، از سامانه پویای NARX بهره گرفته شد که دلیل آن در ضعف سامانه‌های استاتیکی در تشخیص و شبیه‌سازی داده‌هایی با نوسانات زیاد (High Volatile) نهفته است. به‌علاوه، از اتصال مدل‌های ARMA و POWER-GARCH، مدل ترکیبی ARMA-PGARCH طرح‌ریزی شد تا بتواند همزمان جنبه خودبازگشتی میانگین و جمله خطا را هم در معادله میانگین و هم در معادله واریانس منعکس سازد که این مسئله

از دیگر جنبه‌های نوآوری این پژوهش محسوب می‌گردد. سری زمانی انتخاب شده، بازده روزانه شاخص بورس تهران "TEPIX" در دوره زمانی ۱۳۷۶/۰۷/۰۶ تا ۱۳۹۴/۳/۲ بوده و جهت برآورد دقت پیش‌بینی‌ها از ۸ معیار سنجش خطا بهره گرفته شده است. با مقایسه معیارهای خطا، عملکرد کاراتر شبکه عصبی پویا هم در پیش‌بینی درون‌داده‌ای و هم در پیش‌بینی برون‌داده‌ای مشاهده می‌شود. همچنین، نتایج پژوهش حاضر در مورد پیش‌بینی‌پذیر بودن بازدهی بورس تهران، ارائه‌کننده شواهدی مبتنی بر عدم کارایی اطلاعاتی بازار بورس تهران است که این نتیجه‌گیری در راستای یافته‌های پژوهش‌های قبلی در این زمینه است. بنابراین، فرضیه تحقیق که بیان می‌دارد: تفاوت معناداری بین دقت پیش‌بینی مدل پارامتریک پویا و سامانه غیرپارامتریک پویا وجود ندارد، نمی‌تواند پذیرفته شود و شبکه عصبی دینامیک دارای کارایی بهتری در پیش‌بینی بازده بورس می‌باشد. بر اساس یافته‌های این پژوهش پیشنهاد می‌شود که عرضه‌کنندگان و متقاضیان سرمایه و به‌ویژه فعالان بازار بورس تهران، در کنار تحلیل‌های تکنیکال و رویکردهای سنتی مرسوم، از روش‌های نوین هوش مصنوعی نیز بهره‌گیری نمایند.

منابع

- سینایی، حسنعلی؛ مرتضوی، سعیدالله و یاسر تیموری اصل (۱۳۸۴)، "پیش‌بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی"، *بررسی‌های حسابداری و حسابرسی*، سال ۱۲، شماره ۴۱.
- عباسیان، عزت و احسان حسینی‌دوست (۱۳۹۱)، "مقایسه مدل‌های دینامیک خطی و غیرخطی در پیش‌بینی شاخص بورس: مطالعه موردی بورس تهران"، *فصلنامه حسابداری مالی*، شماره ۱۶.
- مشیری، سعید و حبیب مروت (۱۳۸۵)، "پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیرخطی"، *فصلنامه پژوهشنامه بازرگانی*، شماره ۴۱.
- منجمی، سید امیرحسین؛ ابزری، مهدی و علیرضا رعیتی‌شوازی (۱۳۸۸)، "پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک و مقایسه آن با شبکه عصبی مصنوعی"، *فصلنامه اقتصاد مقداری (فصلنامه بررسی‌های اقتصادی)*، شماره ۶، پاییز، صص ۲۶-۱.
- مهرآرا، محسن و قهرمان عبدلی (۱۳۸۵)، "نقش اخبار خوب و بد در نوسانات بازدهی سهام در ایران"، *فصلنامه پژوهش‌های اقتصادی ایران*، سال ۸، شماره ۲۶.

- Apostolos, Paul Refenes (1995), *Neural Networks in the Capital Markets*, Wiley & Sons Pub.
- Avci, Emin (2009), "Stock Return Forecasts with Artificial Neural Networks, Marmara University", I.I.B.F. Dergisiyl, Cilt Xxvi, Sayi 1.
- Box, George & Gwilym Jenkins (1970), *Time Series Analysis: Forecasting and Control*, San Francisco: Holden-Day Pub.
- Chen, S.; Billings S. A. & P. M. Gran. (1990), "Non-Linear System Identification Using Neural Networks", *International Journal of Control*, Vol. 51, No. 6, PP. 1191-1214.
- Chen, W.Y. & Kimilian, K. (2005), "Comparison of Forecasting Models for ASEAN Equity Markets", *Sunway Academic Journal*, Vol. 2, PP. 1-12.
- D. J. C. Mackay (2004), *Information Theory, Inference and Learning Algorithms*, Cambridge University Press, England.
- D. P. Mandic & J. A. Chambers (2001), *Recurrent Neural Networks for Prediction*, John Wiley & Sons.
- Dickman, Greg (2005), *Financial Forecasting and Data Analysis*, Thompson Pub, Nelson Australia Copyright.
- Ding, Zhuixin, Granger C. W. J. Granger, & R. F. Engle (1993), "a Long Memory Property of Stock Market Returns and a New Model," *Journal of Empirical Finance*, Vol 1. PP. 83-106.
- Euge Diaconescu (2008), "The Use of NARX Neural Networks to Predict Chaotic Time Series", *Wseas Transactions on Computer Research*, Issue 3, Vol. 3.
- Fama, E. F. (1970), "A Review of Theory and Empirical Work in Efficient Capita Market", *Journal of Finance*, Vol. 25, PP. 383-417.
- Hang Ou, Phich & Wang Hengshan (2010), "Predicting GARCH, EGARCH and GJR Based Volatility by the Relevance Vector Machine: Evidence from the Hang-Seng Index", *International Research Journal of Finance and Economics*, No. 39.
- Hans, Franses; Dick, Philip & Van Dijk (1996), "Forecasting Stock Market Volatility Using Non-Linear GARCH Models", *Journal of Forecasting*, Vol. 15, PP. 229-235.
- Hung Chun, Liu, Yen Hsien, Lee & Lee Ming Chih (2009), "Forecasting China Volatility Via GARCH Models Under Skewed-GED Distribution", *Journal of Money, Investment and Banking*, No. 7.
- Jung-Hua Wang & Jia-Yannleu (1990), *Stock Market Trend Prediction Using Arima-Based Neural Networks*, National Taiwan Ocean University.
- Klassen, Myungsook (2005), "Investigation of Some Technical Index in Stock Forecasting Using Neural Networks", *World Academy of Science, Engineering and Technology*, No. 5.
- Leonardo S. & Maciel Rosangelaballini (2008), "Design a Neural Network for Time Series Financial Forecasting: Accuracy and Robustness Analysis" Brazilian National Research Council (Cnpq), Grants 30240.

- Lin, Tsungnan & G. Horne Bill & Tino, Peter & C. Lee Giles (1996), "Learning Long-Term Dependencies in NARX Recurrent Neural Networks", *IEEE Transactions on Neural Networks*, Vol. 7, No. 6, PP. 1329-1351.
- M. Shamsuddin, Roselinasalehuddin, Norfadzila & M. Yusof (2008), "Artificial Neural Network Time Series Modeling for Revenue Forecasting", *Chiang Mai J. Sci*, Vol 35, No. 3; PP. 411-426.
- Maciel, L.S. & R. Ballini (2008), "Design a Neural Network for Time Series Financial Forecasting: Accuracy and Robustness Analysis", Brazilian National Research Council (Cnpq), Grants 30240.
- Narendra, K. & K. Parthasarathy (2008), "Identification and Control of Dynamic Systems Using Neural Networks", *IEEE Transactions on Neural Networks*, Vol. 1, No. 1, PP. 4-27.
- Nednegnevitsky, Michel (2002), *Artificial Intelligence: a Guide to Intelligence Systems*, Pearson Education Limited Publish.
- Shadbolt, Jimmy & John, G. Taylor (2002), *Neural Networks and the Financial Marktes*, Springer Pub.
- Tsungnan, Lin, G.; Horne Bill, Tino, Peter & C. Lee Giles (1996), "Learning Long-Term Dependencies in NARX Recurrent Neural Networks", *IEEE Transactions on Neural Networks*, Vol. 7, No. 6, PP. 1329-1351.
- Wang, J. H. & J. Y. Leu (1990), "Stock Market Trend Prediction Using Arima-Based Neural Networks." National Taiwan Ocean University Pub.
- White, H. (1998), "Economic Prediction Using Neural Networks: The Case of IBM Daily Stock Returns", In *Proceeding of the Second Annual IEEE Conference on Neural Networks*, II, PP. 451-485.
- Wong Yoke Chen & Kok Kimilian (2005), "Comparison of Forecasting Models for ASEAN Equity Markets", *Sun way Academic Journal*, Vol. 2, PP. 1-12.
- Yang, Gao Joo & Er Meng. (2005), "NARMAX Time Series Model Prediction: Feed Forward and Recurrent Fuzzy Neural Network Approaches", *Fuzzy Sets and Systems*, Vol. 150, No. 2. PP. 331-350.
- Zivot, E. D. & W. K. Andrews (1992), "Further Evidence on the Great Crash, the Oil-Price Shock and the Unit-Root Hypothesis", *Journal of Business & Economic Statistics*, Vol. 10, No. 3., PP. 251-270

پیوست

نتیجه برآورد مدل ARMA-PGARCH


$$Y_t = 0.0005 + 1.2913(Y_{t-1}) - 0.3300(Y_{t-2}) - 0.8599(\varepsilon_{t-1})$$

(0.0001) (0.0304) (0.0244) (0.0220)

$$\sigma_t^{1.1988} = 5.18e-7 + 0.4634(|\varepsilon_{t-1} - 0.0204(\varepsilon_{t-1})|^{1.1988}) - 0.4487(|\varepsilon_{t-1}|^{1.1988}) + 1.3601(\sigma_{t-1}^{1.1988})$$


(4.96e-7) (0.0539) (0.0048) (0.0526) (0.0515)

$$\bar{R}^2 = 0.1889 \quad SSR = 0.0692 \quad SC = -8.7537 \quad \text{Std.E of PGARCH} = 0.1348$$




نمودار ۱. مقادیر پیش‌بینی درون‌داده‌ای مدل ARMA-PGARCH

نمودار ۲. نتایج رسم توزیع احتمالی داده‌ها



نمودار ۳. نتایج رسم کوانتایل



جدول ۱. مقادیر پیش‌بینی شده برون‌داده ای توسط مدل‌های تحقیق

تاریخ	۱۳۹۴/۲/۲۷	۱۳۹۴/۲/۲۸	۱۳۹۴/۲/۲۹	۱۳۹۴/۲/۳۰	۱۳۹۴/۳/۲
مقادیر واقعی بازده TEPIX	-۰/۰۰۱۱	-۰/۰۱۹۰	۰/۰۰۱۹	۰/۰۱۵۱	۰/۰۰۰۱
بازدهی پیش‌بینی شده توسط مدل ARMA-PGARCH	۰/۰۱۸۹	۰/۰۰۳۷	۰/۰۰۳۹	-۰/۰۰۳۴	-۰/۰۰۷۲
بازدهی پیش‌بینی شده توسط شبکه عصبی NARX	-۰/۰۱۰۱	-۰/۰۱۱۰	-۰/۰۰۱۱	۰/۰۲۱۰	۰/۰۰۱۹

مأخذ: نتایج تحقیق.