

فصلنامه پژوهشنامه بازرگانی، شماره ۴۱، زمستان ۱۳۸۵،

پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیر خطی

دکتر سعید مشیری* حبیب مروت**

پذیرش: ۸۵/۵/۱۶

دریافت: ۸۴/۵/۹

شاخص کل بازدهی سهام تهران / پیش‌بینی / حافظه بلندمدت / شبکه
عصبی (ANN) / GARCH / ARFIMA

چکیده

پیش‌بینی متغیرهای اقتصادی و مالی اهمیت فراوانی برای سیاستگذاران اقتصادی کشورها دارد. در این مقاله شاخص کل بازدهی سهام تهران (TEPIX) با استفاده از داده‌های روزانه و هفتگی این شاخص در بازه زمانی سال ۱۳۷۷ تا ۱۳۸۲ و بکارگیری روش‌های مختلف پیش‌بینی مانند مدل‌های ARIMA، ARFIMA، GARCH و شبکه عصبی (ANN) برآورد و پیش‌بینی شدند. مقایسه دقت پیش‌بینی مدل‌های مذکور از طریق معیارهای پیش‌بینی مانند MAE، RMSE و U-Thiel نشان می‌دهد که مدل ANN در پیش‌بینی شاخص روزانه و هفتگی عملکرد بهتری نسبت به سایر مدل‌ها دارد، اما مقایسه آماری دقت پیش‌بینی مدل‌های مختلف با استفاده از آماره دیلدا-ماریانو، تفاوت معنی‌داری بین دقت پیش‌بینی مدل‌های مذکور را نشان نمی‌دهد.

طبقه‌بندی JEL: C22, C45, G10.

smoshiri@mun.ca

habib_morovat@yahoo.com

* دانشیار دانشکده اقتصاد دانشگاه علامه طباطبایی

** کارشناس ارشد اقتصاد، فارغ التحصیل دانشگاه علامه طباطبایی

مقدمه

پیش‌بینی متغیرهای کلان اقتصادی از اهمیت و جایگاه ویژه‌ای در مباحث علمی اقتصاد برخوردار است و مدل‌های مختلفی برای پیش‌بینی مقادیر آتی متغیرها بوجود آمده‌اند تا سیاست‌گذاران اقتصادی را در اتخاذ سیاست‌های پولی و مالی مناسب یاری نمایند. به همین دلیل امروزه اکثر دولت‌ها و بانک‌های مرکزی در اتخاذ و اجرای سیاست‌هایشان علاوه بر توجه بر وضع موجود، پیش‌بینی‌های کوتاه‌مدت و بلندمدت متغیرهای اصلی اقتصاد را در نظر می‌گیرند.^۱ از طرف دیگر امروزه با رشد روزافزون بازارهای مالی، تغییرات این بازارها می‌تواند آثار بسیار زیادی بر کل اقتصاد جهانی بگذارد. حوادثی مانند حادثه ۱۱ سپتامبر و تخلفات مالی گزارش شده شرکت‌های بزرگ در آمریکا باعث سردرگمی شدید سرمایه‌گذاران و نااطمینانی در مورد عملکرد بازارهای مالی در نواحی مختلف جهان شده است و اعتماد عمومی سرمایه‌گذاران به این بازارها را کاهش داده و اثرات منفی زیادی بر اقتصاد جهان گذاشته است. 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. به همین دلیل 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.^۲

با توجه به اهمیت مسئله پیش‌بینی متغیرهای اقتصادی، مدل‌های مختلفی برای مدلسازی روابط بین متغیرها و پیش‌بینی آن‌ها بوجود آمده‌اند. این مدل‌ها را می‌توان از چند جهت تقسیم‌بندی نمود: مدل‌های سری‌زمانی و ساختاری یا مدل‌های خطی و غیرخطی. در

۱. مشیری (۱۳۸۰)، صفحات ۱۸۴-۱۴۷.

۲. Guerard & Newbold (1986); Peters (1992).

مدل‌های ساختاری روابط متغیرهای اقتصادی بر مبنای رفتار عقلایی عوامل اقتصادی اعم از مصرف‌کنندگان، تولیدکنندگان و سیاست‌گذاران اقتصادی بنا نهاده می‌شود و با استفاده از مدل‌های مختلف اقتصادسنجی برآورد شده و از آنها در تبیین وضع موجود و پیش‌بینی مقادیر آتی متغیر وابسته استفاده می‌شود. از آنجایی که در این مدل‌ها سهم نسبی هر یک از عوامل مستقل در تغییرات متغیر وابسته مشخص است می‌توان از آنها در سیاست‌گذاری نیز استفاده نمود. هرچند این مدل‌ها در تبیین وضع موجود از موفقیت نسبی برخوردار می‌باشند اما در زمینه پیش‌بینی سابقه چندان موفقی نداشته‌اند. اهمیت روز افزون پیش‌بینی برای عوامل اقتصادی از یک طرف و کاستی مدل‌های ساختاری در پیش‌بینی از طرف دیگر منجر به توسعه مدل‌های سری زمانی برای مدلسازی و پیش‌بینی شد. در مدل‌های سری زمانی فرض می‌شود تمام عوامل و ارتباطات مؤثر در شکل‌گیری یک متغیر در مقادیر خود آن نمود پیدا می‌کند، بنابراین از مقادیر قبلی خود متغیر می‌توان به عنوان مهمترین منبع برای توضیح تغییرات متغیر استفاده نمود و پیش‌بینی را تنها با استفاده از اطلاعات قبلی خود متغیر انجام داد. بر طبق این دیدگاه اگر بتوان فرآیند مولد داده‌های یک متغیر را بدست آورد پیش‌بینی آن متغیر نسبتاً براحتی امکان‌پذیر خواهد بود. اما از آنجایی که در مدل‌های سری‌های زمانی سهم نسبی سایر عوامل مؤثر در تغییرات متغیر وابسته مشخص نیست آنها از کاربرد کمتری در سیاست‌گذاری برخوردار هستند. باید توجه داشت هنگامی نتایج پیش‌بینی مدل‌های سری‌زمانی از اعتبار کافی برخوردار خواهد بود که بتوان فرآیند مولد مقادیر یک متغیر را بخوبی بدست آورد¹. فرآیند مولد یک سری‌زمانی ممکن است خطی یا غیرخطی باشد. با توجه به آنکه معمولاً عوامل و نیروهای پیچیده بسیاری باعث تغییر پدیده‌های اقتصادی می‌شوند که احتمالاً از روابط غیرخطی تبعیت می‌کنند، مدل‌های سری‌زمانی غیرخطی و پویا از جایگاه مهمی در ادبیات اقتصادی مدل‌های پیش‌بینی (به‌ویژه در دهه اخیر) برخوردار شده‌اند و در حال حاضر نقش مهمی در مدلسازی روابط اقتصادی که یک مرحله اصلی در پیش‌بینی‌های کوتاه‌مدت و بلندمدت می‌باشند ایفا می‌نمایند. از طرف دیگر بخاطر اینکه مدل‌های سری‌زمانی فرآیندهای پیچیده

1. مشیری، فروتن (۱۳۸۳).

را که بطور ناقص درک و استنباط می‌گردند را ساده‌سازی می‌نمایند، ترکیب و ادغام پیش‌بینی مدل‌های مختلف می‌تواند نتایج بهتری از پیش‌بینی یک مدل خاص داشته باشد. در نهایت باید توجه داشت هرچند که روش‌های پیش‌بینی از نقطه نظر نظری مورد توجه می‌باشند اما آن‌ها، در نهایت باید بوسیله توانایی‌هایشان در کاربردهای واقعی پیش‌بینی‌های اقتصادی سنجیده شوند^۱.

با توجه به اهمیت پیش‌بینی متغیرهای اقتصادی مخصوصاً متغیرهای مالی، در این تحقیق شاخص قیمت سهام بورس تهران (TEPIX) با استفاده از چهار مدل مختلف سری‌زمانی خطی و غیرخطی پیش‌بینی می‌شود. این مدل‌ها عبارتند از: مدل خودرگرسیون میانگین متحرک (ARIMA)، مدل‌های نوع GARCH، مدل شبکه عصبی مصنوعی (ANN)^۲، مدل ARFIMA^۳. از آنجا که قیمت‌های سهام و بازدهی آن‌ها از پیچیدگی‌های زیادی برخوردارند بنظر می‌رسد که مدل‌های انعطاف پذیر غیرخطی مانند مدل شبکه عصبی مصنوعی برای پیش‌بینی آن‌ها بهتر از مدل‌های استاندارد خطی عمل خواهند کرد. در این مقاله، به دنبال ارزیابی فرضیه فوق و به طور مشخص پاسخ به این سؤال هستیم که آیا مدل شبکه عصبی از قدرت پیش‌بینی بیشتری نسبت به مدل‌های ARIMA، GARCH و ARFIMA در پیش‌بینی TEPIX برخوردار است؟

در این تحقیق، از مدل‌های سری‌زمانی تک متغیره برای پیش‌بینی استفاده می‌شود زیرا اولاً طراحی و اجرای این مدل‌ها سریع و نسبتاً ساده بوده و از نظر کیفیت پیش‌بینی نیز توانایی مقایسه با مدل‌های پیش‌بینی چند متغیره را دارند. ثانیاً ممکن است اطلاعات سایر متغیرهای مرتبط با پیش‌بینی در دسترس نباشد یا بدست آوردن آن‌ها هزینه بسیار زیادی نیاز داشته باشد. ثالثاً با استفاده از این روش می‌توان فهمید تا چه میزان از تغییرات یک متغیر بوسیله مقادیر قبلی آن متغیر توضیح داده می‌شود.

در ادامه این تحقیق، ابتدا مدل‌های پیش‌بینی و نحوه برآورد آن‌ها توضیح داده شده سپس ادبیات مدل‌های پیش‌بینی مورد استفاده در تحقیق تشریح خواهد شد. در بخش

1. Poon & Granger (2003).

2. Artificial Neural Networks.

3. Auto Regressive Fractionally Integrated Moving Average.

چهارم داده‌های استفاده شده در تحقیق معرفی می‌شوند. در بخش‌های پنج و شش نتایج پیش‌بینی ارائه شده و دقت پیش‌بینی مدل‌ها با یکدیگر مقایسه می‌شوند. جمع‌بندی مقاله در بخش آخر خواهد آمد.

۱. مدل‌های پیش‌بینی

برای پیش‌بینی شاخص بازدهی قیمت سهام از مدل خطی ARIMA و مدل‌های غیرخطی ARFIMA، GARCH و شبکه عصبی (ANN) استفاده کرده‌ایم که در این قسمت مروری کوتاه بر آن‌ها خواهیم داشت. با توجه به نسبتاً جدید بودن مدل‌های ARFIMA و ANN توضیحات بیشتری در مورد آنان در اینجا ارائه می‌شود.

۱-۱. مدل خودرگرسیون میانگین متحرک (ARIMA)^۱

مدل ARIMA یک مدل خطی-تصادفی می‌باشد که از قدیمی‌ترین مدل‌های پیش‌بینی سری‌های زمانی در اقتصادسنجی است که از آن برای پیش‌بینی سری‌های زمانی که مانا^۲ نیستند ولی می‌توان آن‌ها را با استفاده از تفاضل‌گیری با مرتبه صحیح مانا نمود استفاده می‌شود.

برای پیش‌بینی با مدل $ARIMA(p,d,q)$ از متدولوژی باکس-جنکینز استفاده می‌شود که دارای ۴ مرحله شناسایی، برآورد، آزمون‌های کنترل تشخیصی و پیش‌بینی می‌باشد.^۳

۱-۲. مدل خود رگرسیون ناهمسان واریانس شرطی (ARCH)^۴

مدت نسبتاً طولانی است که اقتصادسنجی دانان و محققان پی‌برده‌اند که بازدهی‌های دارایی‌های مالی دارای ویژگی خوشه‌بندی تغییرات^۵ می‌باشد؛ یعنی توزیع احتمال فراوانی آن‌ها چولگی و کشیدگی بیشتری از توزیع احتمال فراوانی نرمال دارد. اما تنها در دو دهه

1. Auto Regressive Integrated Moving Average.

2. Stationary.

3. اصغری اسکویی (۱۳۸۱) و Granger & Newbold (1986).

4. Auto Regression Conditionally Hetrokedasticity.

5. Volatility Clustering.

اخیر مدل‌های آماری که بتوانند این وابستگی‌ها را نشان دهند بوجود آمده‌اند. اولین مدل برای توضیح وابستگی از نوع خوشه‌بندی تغییرات سری‌های زمانی توسط انگل (۱۹۸۲) مطرح شد. وی مدل خودرگرسیون واریانس ناهمسان شرطی (ARCH) را برای توجیه این نوع از وابستگی‌ها در سری‌های زمانی مطرح نمود. بعد از وی مطالعات گوناگونی توسط سایر اقتصاددانان مانند بولرسلف^۱ صورت گرفت و مدل‌های دیگری از نوع ARCH مانند مدل خودرگرسیون واریانس ناهمسان شرطی تعمیم‌یافته (GARCH)^۲ بوجود آمدند تا بتوانند این ویژگی بازدهی‌های دارایی‌های مالی را به خوبی توضیح دهند.

تجزیه و تحلیل سری‌های زمانی نشان می‌دهد که پیش‌بینی‌های مبتنی و مشروط بر اطلاعات قبلی کاراتر از پیش‌بینی‌هایی است که از این اطلاعات استفاده نمی‌کنند. مدل ARCH نیز با توجه به این نتایج برای پیش‌بینی واریانس مقادیر آتی، از اطلاعات قبلی مربوط به واریانس سری‌های زمانی استفاده می‌کند. از آنجایی که خوشه‌بندی تغییرات به طور ضمنی بیان می‌کند که هر تغییر ناگهانی بزرگ با هر علامتی (مثبت یا منفی) احتمال تغییرات آتی را افزایش می‌دهد، بنابراین پیش‌بینی تغییرات که این حقیقت (خوشه‌بندی تغییرات) را در نظر می‌گیرند، معمولاً دقیق‌تر از پیش‌بینی‌هایی خواهند بود که آن را در نظر نمی‌گیرند.^۳

انواع مختلفی از مدل‌های نوع ARCH در مدل‌سازی و پیش‌بینی اقتصادی استفاده می‌شود که معروفترین این مدل‌ها عبارتند از: مدل ARCH(q)، مدل GARCH(p,q)، مدل ARCH-M، مدل EGARCH، مدل IGARCH.^۴ از هر یک از این مدل‌ها با توجه به نوع و مشخصه‌های داده‌های بکار گرفته شده در پیش‌بینی استفاده می‌شود، اما بیشتر مطالعات تجربی نشان داده‌اند که مدل‌های نوع GARCH از توانایی بیشتری در مدل‌سازی و پیش‌بینی بازارهای سهام برخوردار می‌باشد.

-
1. Bollerslev.
 2. Generalized Auto Regression Conditionally Hetrokedasticity.
 3. Edgar (1992).
 4. ARCH in Mean Model.
 5. Exponential GARCH.
 6. Integrated GARCH.

۳-۱. مدل شبکه عصبی مصنوعی^۱ (ANN)

امروزه مدل‌های دیگری به موازات مدل‌های پیش‌بینی سنتی در ادبیات مدل‌های پیش‌بینی اقتصادی وارد شده‌اند. این مدل‌ها با استفاده از هوش مصنوعی، روابط بین متغیرها را هرچقدر هم که پیچیده باشند یاد گرفته و از آن برای پیش‌بینی مقادیر آتی متغیرها استفاده می‌نمایند. این روش که اقتباسی از فرآیند یادگیری مغز انسان (هوش طبیعی) است ابتدا در سایر رشته‌های علمی مانند فیزیک، کامپیوتر و علوم مهندسی در زمینه‌های شناخت الگو^۳، خوشه‌بندی^۴، مدل‌سازی، طبقه‌بندی و کنترل بکار می‌رفت، اما اقتصاددانان از اواخر دهه ۱۹۸۰ با استفاده از این مدل‌های موسوم به شبکه عصبی مصنوعی اقدام به شناسایی، تخمین، مدل‌سازی و پیش‌بینی متغیرهای اقتصادی نمودند به طوری که امروزه این مدل جایگاه مهمی در ادبیات پیش‌بینی متغیرهای اقتصادی به خود اختصاص داده است. مهمترین مزیت این مدل نسبت به سایر مدل‌های ساختاری و سری‌زمانی آن است که در طراحی این مدل‌ها نیازی به اعمال فرض آماری خاص در مورد رفتار متغیرها مانند فروض مربوط به تابع توزیع احتمال آن‌ها و یا اعمال فروض مربوط به نحوه ارتباط بین متغیرها نیست. البته همین نقطه قوت مدل‌های شبکه عصبی یعنی آزادی آن‌ها از قیود مفروضات مدل‌های آماری و سنجی، از نظر برخی از اقتصاددانان نقطه ضعف آن نیز به شمار می‌رود، زیرا از نظر آن‌ها اگر نتوان نتایج حاصل از این مدل‌ها را از لحاظ آماری ارزیابی کرد به عنوان مثال سطح اعتماد مقادیر پیش‌بینی شده را مشخص نمود، نمی‌توان از آن‌ها نتایج آماری معتبری را استنتاج نمود. اما وایت^۵ (۱۹۹۴) تا حدودی موفق شد ویژگی‌های آماری این مدل‌ها و انطباق آن‌ها را با مفاهیم رگرسیون نشان دهد^۱.

از آنجایی که برای مدل‌سازی و پیش‌بینی با این مدل‌ها نیاز به داده‌های فراوان می‌باشد و متغیرهای مالی دارای طولانی‌ترین سری‌های زمانی در اقتصاد هستند و همچنین معمولاً

۱. برای آشنایی بیشتر با مدل شبکه عصبی به مشیری (۱۳۸۰) و Jungeiligis (1996) مراجعه نمایید.

2. Artificial Neural Networks
3. Pattern Recognition
4. Clustering
5. White

۶. آذر و رجبزاده (۱۳۸۲)؛ قاسمی، اسدپور و شاصادقی (۱۳۷۷)؛ مشیری (۱۳۸۰).

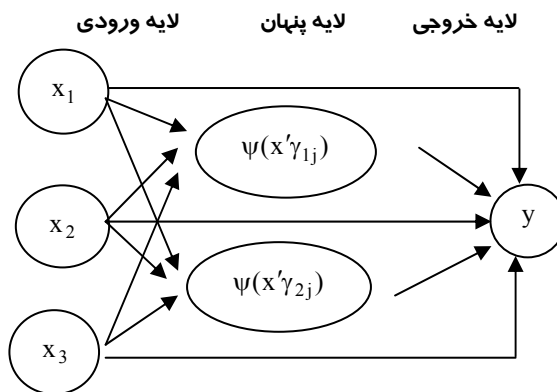
توزیع‌های احتمال مربوط به متغیرهای مالی از توزیع‌های احتمال استاندارد و شناخته شده تبعیت نمی‌کنند، متغیرهای مالی یکی از وسیع‌ترین زمینه‌های کاربردی این مدل‌ها در پیش‌بینی هستند.

۱-۳-۱. ساختار مدل‌های شبکه عصبی مصنوعی

مدل‌های شبکه‌های عصبی مصنوعی را می‌توان در قالب نظیرکننده‌های برداری جای داد بطوریکه مجموعه‌ای از داده‌ها را گرفته و توسط برنامه‌هایی که توانایی انجام عملیات بصورت موازی و پردازش غیرخطی با حجم بسیار زیاد را دارند ستاده‌هایی را تحویل می‌دهند.^۱

مدل‌های شبکه مصنوعی انواع مختلفی دارند اما ساختار کلی آن‌ها مشابه می‌باشد. یک شبکه عصبی مصنوعی معمولاً از بخش‌های زیر تشکیل شده است که شمای کلی آن در شکل (۱) نشان داده شده است.

شکل ۱: نمای کلی یک شبکه عصبی پیشرو



• لایه‌ها

تمامی مدل‌های شبکه عصبی مصنوعی دارای سه نوع لایه می‌باشند که عبارتند از:

1. مشیری (۱۳۸۰).

۱- لایه ورودی^۱: در این لایه به تعداد متغیرهای توضیحی مدل، واحدهایی وجود دارند که هر یک از آن‌ها داده‌های مربوط به یک متغیر توضیحی را شامل می‌شوند. در واقع، این لایه مشابه بردار متغیرهای توضیحی در مدل رگرسیون است.

۲- لایه‌های میانی (پنهان)^۲: در این لایه واحدهای پردازشگر اطلاعات قرار دارند که نقش بسیار مؤثری در فرآیند یادگیری (برآورد) صحیح مدل ایفا می‌کنند. یک مسئله ضروری و مهم در طراحی یک شبکه تعیین تعداد واحدهای لایه پنهان است اما متأسفانه هیچ جواب واحدی برای تعیین تعداد این لایه‌ها و واحدهای پردازش اطلاعات در این لایه‌ها وجود ندارد. اما تعداد این لایه‌ها و واحدهای پردازشگر آن‌ها طوری باید انتخاب شوند که در آموزش و پیش‌بینی، دچار بیش‌برازش^۳ و یا حفظ کردن^۴ و فرآیند یادگیری ناقص نشویم^۵.

۳- لایه خروجی^۶: در این لایه عمل پردازش بر روی اطلاعات ارسال شده از لایه پنهان صورت می‌گیرد. تعداد واحدهای این لایه به اندازه تعداد متغیرهای درون‌زای مدل می‌باشد. این لایه مشابه بردار متغیرهای وابسته در مدل رگرسیون است.

• واحدهای پردازش^۷

پردازشگرها واحدهایی هستند که در لایه‌های پنهان و خروجی قرار دارند و با استفاده از توابع فعالسازی یا تبدیل، اطلاعات را پردازش کرده و به لایه بعدی ارسال می‌نمایند. این واحدها جنبه‌های مختلف یک الگو را یک‌جا در نظر گرفته و از فرآیند پردازش توزیع شده موازی (PDP) استفاده می‌نمایند. عمل این پردازشگرها همانند عمل نرون‌ها در شبکه‌های عصبی طبیعی است^۸.

1. input layer.
2. hidden layer.
3. Overestimate.
4. Memorization.
5. Kohzadi et al (1996).
6. output layer.
7. Processing unit.

8. قاسمی، اسدپور و شاصادقی (۱۳۷۷).

• توابع فعال‌سازی (تبدیل)^۱

هر یک از واحدهای پردازشگر در لایه‌های پنهان و خروجی برای پردازش اطلاعات از توابع ریاضی معینی استفاده می‌کنند که توابع فعال‌سازی یا تبدیل نامیده می‌شوند. این توابع معمولاً غیرخطی می‌باشند. مهمترین توابع تبدیل مورد استفاده در مدل‌های شبکه‌های عصبی تابع سیگموئید^۲ و تابع تانژانت هیپربولیک می‌باشند. توابع دیگری نیز به عنوان توابع فعال‌سازی استفاده می‌شوند که می‌توان تابع گوسین^۳، تابع آستانه‌ای^۴ و تابع خطی همانی $f(x) = x$ که معمولاً برای نرون لایه خروجی استفاده می‌شود، نام برد.

یک مسئله مهم اثبات شده در مورد مدل‌های شبکه عصبی آن است که یک مدل شبکه عصبی پیشخور با یک لایه پنهان با تابع فعال‌سازی سیگموئید در لایه پنهان و تابع فعال‌سازی خطی در نرون خروجی و تعداد نرون‌های کافی در لایه پنهان قادرند هر تابعی را با دقت دلخواه تقریب بزنند. این مسئله نشان دهنده آن است که طراحی یک مدل شبکه عصبی مناسب اهمیت قابل توجهی در برآورد و پیش‌بینی یک فرآیند دارد.^۵

۲-۳-۱. چگونگی پردازش اطلاعات در واحدهای پردازشگر

هر واحد پردازشگر اطلاعات (نرون‌ها) در لایه‌های میانی و خروجی دو عمل را انجام می‌دهند. ابتدا مجموع حاصل ضرب اطلاعات ورودی و وزن‌های ارتباطی (پارامترهایی که مقادیر اولیه آن‌ها معمولاً تصادفی تعیین می‌شوند) را محاسبه می‌کنند، سپس این اطلاعات را توسط توابع تبدیل پردازش کرده و به واحد پردازشگر بعدی ارسال می‌نمایند. انواع مختلفی از مدل‌های شبکه عصبی وجود دارد. این مدل‌ها در یک طبقه‌بندی به مدل‌های ایستا^۶ و پویا^۷ طبقه‌بندی می‌شوند. در مدل‌های ایستا (پیشخور^۸) مسیر پردازش اطلاعات از داده‌ها به ستاده است بدون آنکه بازگشتی در سیستم ارتباطی واحدها وجود

1. activity (transfer) function.
2. sigmoid function.
3. Gaussian.
4. Threshold.

5. منبع پیشین.

6. Static.
7. Dynamic.
8. Feed forward.

داشته باشد. در حالیکه در مدل‌های پویا مسیر برگشتی از بردار ستاده یا بردار واحدهای میانی به بردار داده‌ها نیز وجود دارد. این مسیرهای بازگشتی را می‌توان به متغیرهای با وقفه در مدل رگرسیون معمولی تشبیه نمود. زیرا در این حالت ستاده‌ها نه تنها تابعی از متغیرهای مستقل بوده بلکه تابعی از ستاده‌های دوره‌های قبلی نیز می‌باشند. یک طبقه‌بندی دیگر در مورد مدل‌های شبکه عصبی به این صورت است که اگر بردار داده‌ها با بردار ستاده‌ها متفاوت باشند مدل دگرهمراهی^۱ و چنانچه بردار داده‌ها با بردار ستاده‌ها یکسان باشند مدل خود همراهی^۲ نامیده می‌شود.^۳

۳-۱-۳. فرآیند یادگیری^۴ در مدل‌های شبکه عصبی

فرآیند یادگیری در مدل‌های شبکه عصبی در واقع برآورد وزن‌ها و پارامترهای مدل می‌باشد که این عمل به دو روش می‌تواند انجام شود: یادگیری با نظارت^۵ و یادگیری بدون نظارت^۶. در یادگیری تحت نظارت مقادیر واقعی متغیر هدف (وابسته) به همراه متغیرهای ورودی به شبکه داده می‌شود. شبکه پس از باز تولید مقادیر متغیر وابسته با استفاده از متغیرهای ورودی آن‌ها را با مقادیر واقعی متغیر وابسته مقایسه نموده و اختلاف (خطای) هر مشاهده را اندازه می‌گیرد. سپس با استفاده از الگوریتم‌های مختلف تکرار مانند الگوریتم پس انتشار خطا^۷، وزن‌های شبکه تعدیل می‌گردد تا خطاهای مورد نظر که بوسیله معیارهای مختلف مانند ریشه میانگین مربعات خطاها (RMSE)^۸ یا میانگین قدر مطلق خطاها (MAE)^۹ اندازه‌گیری می‌شوند، حداقل گردند. به این ترتیب شبکه آموزش داده شده و وزن‌ها و پارامترهای شبکه برآورد می‌شوند.

می‌توان از الگوریتم‌های متفاوتی برای آموزش شبکه عصبی استفاده کرد. مهمترین

1. hetro- association.

2. Auto-association.

3. مشیری (۱۳۸۰) و (1996) Jungeiliges.

4. Learning (training).

5. Supervised Learning.

6. Unsupervised Learning.

7. Error back-propagation.

8. root of mean square error.

9. Mean absolute Error.

الگوریتم آموزش شبکه عصبی در یادگیری تحت نظارت، الگوریتم پس انتشار خطا می باشد. مدل پس انتشار خطا (BPN)^۱ از نوع ایستا و دگرهمراهی بوده که معمولاً از سه لایه ورودی، پنهان و خروجی تشکیل می شود. در یادگیری بدون نظارت، خروجی مطلوب برای شبکه تعریف نمی شود و فقط ورودی ها به شبکه داده می شود.^۲

۴-۱. مدل خودرگرسیون میانگین متحرک انباشته جزئی (ARFIMA)^۳

بعد از مطالعات مهم در مورد وجود ریشه واحد و هم انباشتگی در سری های زمانی که از اواسط دهه ۱۹۸۰ آغاز شده بود اقتصادسنجی دانان زیرگونه ها و انواع دیگری از نامانایی و پایداری^۴ تقریبی را که فرآیند موجود در بسیاری از سری های زمانی مالی و اقتصادی را توجیه می کردند، مورد بررسی قرار دادند. بطوریکه امروزه مطالعات گوناگونی در مورد این نوع از فرآیندها از جمله حرکت براونی فراکتالی^۵، فرآیندهای انباشته بطور جزئی^۶ و فرآیندهای با حافظه بلندمدت^۷ صورت گرفته است. هرست^۸ (۱۹۵۱) برای اولین بار به وجود فرآیندهای دارای حافظه بلندمدت در زمینه هیدرولوژی پی برد. بعد از وی و از اوایل دهه ۱۹۸۰ اقتصادسنجی دانانی مانند گرنجر و جویکس^۹ (۱۹۸۰)، گرنجر (۱۹۸۱) و هاسکینگ^{۱۰} (۱۹۸۱) به طراحی مدل های اقتصادسنجی دارای فرآیندهای با ویژگی حافظه بلندمدت پرداخته و ویژگی های آماری این مدل ها را مشخص نمودند. معروفترین و انعطاف پذیرترین این مدل ها امروزه در زمینه اقتصادسنجی، مدل خودرگرسیون میانگین متحرک انباشته جزئی (ARFIMA) نامیده می شود. گویک و پورتر-هوداک^{۱۱} (۱۹۸۳) روشی برای برآورد پارامترهای مدل فوق مطرح کردند. در سال های اخیر مطالعات تحقیقی

1. Back-propagation network.

2. قاسمی، اسدپور و شاصادقی (۱۳۷۷)، مشیری (۱۳۸۰).

3. Auto Regression Fractionally Integrated Moving Average.

4. Persistence.

5. Fractional Brownian Motion.

6. Fractionally Integrated Process.

7. Long Memory Process.

8. Hurst.

9. Granger & Joyeux.

10. Hosking.

11. Geweke & Porter-Hodak.

حرکت و تمرکز خود را بر روی برآورد و آزمون دامنه وسیعی از فرایندهای با حافظه بلندمدت و همچنین بر کاربردهای آنها در بسیاری از زمینه‌های اقتصادی و مالی گذاشته‌اند.^۱

۱-۴-۱. مفهوم حافظه بلندمدت

در ادبیات اقتصادسنجی چندین تعریف از مفهوم "حافظه بلندمدت" مطرح شده که در این قسمت دو تعریف از این مفهوم که دارای بیشترین اهمیت هستند بیان می‌گردد:^۲
 مک‌لئود و هیپل^۳ (۱۹۷۸) حافظه بلندمدت را چنین تعریف نمودند:
 فرض کنید y_t یک سری زمانی گسسته با تابع خودهمبستگی ρ_j در وقفه زمی باشد، فرآیندی دارای حافظه بلندمدت است که مقدار

$$\lim_{n \rightarrow \infty} \sum_{j=-n}^n |\rho_j|$$

نامحدود باشد.

در حالیکه یک فرآیند ARMA خود همبستگی‌هایی دارد که بطور هندسی محدود شده‌اند یعنی برای مقادیر بزرگ k و $0 < m < 1$ ، $|\rho_k| \leq cm^{-k}$. بنابراین این فرآیند یک فرآیند با حافظه کوتاه‌مدت است.

گرنجر و دینگ^۴ (۱۹۹۶) حافظه بلندمدت را با استفاده از نمودار همبستگی تشریح نمودند. نمودارهای همبستگی سری‌های زمانی دارای حافظه بلندمدت برخلاف سری‌های زمانی که به صورت نمایی کاهش می‌یابد، به صورت هیپربولیکی و با نرخ آهسته‌تری کاهش می‌یابد.

بنابراین با توجه به تعاریف فوق از حافظه بلندمدت، فرآیند انباشته جزئی (فراکتالی) با توجه به رابطه بالا فرآیندهای با حافظه بلندمدت هستند. فرآیند y_t انباشته جزئی از مرتبه d می‌باشد اگر

-
1. Baillie & King (1996).
 2. Baillie (1996).
 3. McLeod & Hipel.
 4. Ding.

$$(1-L)^d y_t = u_t$$

در این رابطه L اپراتور وقفه، $-0.5 < d < 0.5$ و u_t فرآیند مانا بوده و در تمام فرکانس‌ها دارای طیف ارزیابی مثبت می‌باشد. حال اگر u_t انباشته از مرتبه صفر و مانای ضعیف بوده و $0 < d < 0.5$ ، فرآیند y_t با توجه به تعریف دوم دارای حافظه بلندمدت بوده و خودهمبستگی‌هایش همگی مثبت بوده و با نرخ هیپربولیکی از بین می‌روند. به ازای $0 < d < -0.5$ مجموع قدرمطلق مقادیر خودهمبستگی فرآیندها به یک مقدار ثابت میل کرده و بنابراین بر طبق تعریف اول دارای حافظه کوتاه‌مدت می‌باشند.

۲-۴-۱. مدل ARFIMA

مدل‌های ARMA سیستم‌های نامانای همگن هستند که می‌توانند به وسیله تفاضل‌گیری متوالی از مشاهدات مانا گردند. مدل عمومی $ARIMA(p,d,q)$ می‌تواند شامل اجزاء خودرگرسیون و میانگین متحرک به صورت مجزا و یا ادغام شده باشد. در این مدل d (پارامتر تفاضل‌گیری) همواره یک عدد صحیح می‌باشد. اما گرنجر و جویکس (۱۹۸۰)، گرنجر (۱۹۸۱) و هاسکینگ (۱۹۸۱) مدل اولیه $ARIMA(p,d,q)$ را تعمیم دادند بطوریکه در مدل جدید d می‌توانست هر عدد واقعی (صحیح یا غیرصحیح) را شامل شود. آن‌ها مدل جدید را مدل خودرگرسیون میانگین متحرک انباشته جزئی (ARFIMA) نامیدند. این مدل مهمترین و انعطاف‌پذیرترین گروه از مدل‌های دارای حافظه بلندمدت می‌باشند که می‌توانند رفتار پایدار و ناپایدار^۱ تولید نمایند. فرآیند $ARFIMA(0,d,0)$ حرکت براونی فراکتالی^۲ می‌باشد که توسط ماندلبرات و والیس^۳ (۱۹۶۹) معرفی شد. بخاطر اینکه فرآیند عمومی تر $ARFIMA(p,d,q)$ می‌تواند فرآیندهای با حافظه کوتاه‌مدت AR و MA و همچنین فرآیندهای با حافظه بلندمدت را شامل شود، این مدل بطور بالقوه توانایی توضیح و توصیف تغییرات در اکثر بازارها را دارد. این مدل با گسترش و تعمیم مدل‌های مرسوم

1. Antipersistence.

2. حرکت براونی معادل گام تصادفی در زمان پیوسته است، و حرکت براونی فراکتالی نویز سفیدی است که بطور غیر صحیح تفاضل‌گیری شده است.

3. Mandelbrot & Wallis.

می‌تواند فرضیه بازارهای فراکتالی^۱ که در دهه اخیر در بازارهای مالی مطرح شده است را توضیح دهد.^۲

مدل ARFIMA(p,d,q) دارای شکل کلی بصورت زیر است:^۳

$$\Phi(L)(1-L)^d(y_t - \mu) = \Theta(L)\varepsilon_t, \varepsilon_t \approx \text{iid}(0, \sigma^2)$$

در این رابطه d پارامتر تفاضل‌گیری، μ می‌تواند هر نوع تابع معین از زمان باشد و L اپراتور وقفه است به طوری که $y_{t-1} = Ly_t$ ، بنابراین چند جمله‌ای‌های $\Phi(L)$ و $\Theta(L)$ که به ترتیب نشان‌دهنده مرتبه خودرگرسیون و میانگین متحرک سری می‌باشند.

برای اینکه این فرآیند معکوس‌پذیر و مانا باشد باید ریشه‌های $\Phi(L) = 0$ و $\Theta(L) = 0$ خارج از دایره واحد بوده و ریشه مشترک نداشته باشند و همچنین $|d| < 0.5$. اما از آنجائیکه وقتی $k \rightarrow \infty$ ، همانطور که هوسکینگ نشان داده است $\rho_k \propto k^{2d-1}$ ، بنابراین مجموع خودهمبستگی‌ها محدود نبوده در نتیجه فرآیندهای ARFIMA به ازای $0 < d < 0.5$ با توجه به تعریف اول از فرآیندهای با حافظه بلندمدت، دارای حافظه بلندمدت می‌باشند. به عبارت دیگر این فرآیندها پایداری بیشتری از خود نشان داده و تابع خود همبستگی آن‌ها بسیار آهسته‌تر از تابع خودهمبستگی فرآیندهای ARIMA میرا می‌شوند.

هنگامی که $0.5 < d < 1$ است، به علت اینکه واریانس فرآیند محدود نیست، فرآیند y_t مانا و معکوس‌پذیر نمی‌باشد. هرچند که سری در این حالت نامانا است می‌توان از طریق فرمول هاسکینگ پی‌برد که تابع خودهمبستگی هنوز به صفر میل می‌کند. این مسئله بطور ضمنی نشان می‌دهد که حافظه فرآیند محدود بوده و شوک وارد بر فرآیند در میانگین نمود پیدا می‌کند به همین دلیل به این فرآیندها برگشت به میانگین^۴ می‌گویند. هنگامی که $d > 1$ است، فرآیند برگشت به میانگین نبوده و شوک وارد بر فرآیند باعث می‌شود که فرآیند از نقطه آغازین خودش منحرف گردد.^۵

بنابراین حافظه فرآیند ARFIMA شدیداً به مقدار d و نحوه میرایی توابع خودهمبستگی

1. Fractal Market Hypothesis.
2. Baillie & King (1996); Oomen (2001).
3. Kohzadi et al (1996).
4. Mean-Reverting.
5. Oomen (2001).

بستگی دارد.

۱-۲-۴-۱. برآورد مدل ARFIMA

سه روش برای برآورد مدل ARFIMA و پارامتر d وجود دارد که عبارتند از روش دو مرحله‌ای، حداکثر درستنمایی تقریبی^۱ و روش حداکثر درستنمایی دقیق^۲ (EML)^۳. در این تحقیق از نرم افزار OX و روش EML برای برآورد و پیش‌بینی مدل استفاده می‌شود.

۲. مروری بر پیشینه مدل‌های پیش‌بینی استفاده شده در تحقیق

در اکثر مطالعات انجام شده در زمینه پیش‌بینی متغیرهای اقتصادی، بویژه متغیرهای مالی که تاکنون انجام شده است مدل‌های غیرخطی انعطاف‌پذیر مانند شبکه عصبی و مدل‌های متکی بر حافظه بلندمدت مانند ARFIMA از عملکرد بهتری برخوردار بوده‌اند. در این بخش مروری کوتاه بر برخی مطالعات موجود در جهان و ایران خواهیم داشت.

بارکالوس، باوم و تراولس^۴ (۱۹۹۷) وجود حافظه بلندمدت در شاخص بازدهی بازار سهام یونان ($300^{\circ}ASE$) را بررسی نموده و با استفاده از رگرسیون طیفی وجود حافظه بلندمدت مثبت دقیق و قوی در این بازار را نشان دادند. سپس آن‌ها این شاخص را با استفاده از مدل‌های ARFIMA، AR و گام تصادفی در افق زمانی یک هفته تا سه هفته و ۱ تا ۱۲ ماه پیش‌بینی نموده و با استفاده از معیارهای ارزیابی دقت پیش‌بینی RMSE و MAD نشان دادند که مدل‌های ARFIMA و AR در تمام افق‌های زمانی پیش‌بینی دقت بیشتری از مدل گام تصادفی دارند. همچنین آن‌ها نشان دادند که مدل ARFIMA به ازای مقادیر مختلف d از قدرت پیش‌بینی بیشتری نسبت به مدل AR برخوردار است^۵.

اومن^۶ (۲۰۰۱) وجود حافظه بلندمدت در داده‌های لحظه به لحظه تغییرات شاخص بازار

1. Approximate Maximum Likelihood.

2. Exact Maximum Likelihood.

3. Leung, Daouk & Chen (2000).

4. Barkoulas, Baum & Travlos.

5. Athens Stock Exchange.

6. Ibid.

7. Oomen.

سهام انگلیس (FTSE 100) را با استفاده از مدل ARFIMA نشان داد. وی سپس نتایج پیش‌بینی خارج از نمونه این شاخص را که با استفاده از مدل‌های ARFIMA و GARCH پیش‌بینی شده بودند را مقایسه نمود و با استفاده از معیار SSE نشان داد که مدل ARFIMA از دقت پیش‌بینی بیشتری نسبت به مدل GARCH برخوردار است.^۱

دونیس و جلیلوف^۲ (۲۰۰۱) با استفاده از مدل شبکه عصبی به برآورد و پیش‌بینی چهار شاخص مهم بازار سهام یعنی S&P500، FTSE100، EUROSTOXX50 و NIKKEI225 پرداخته‌اند. آن‌ها برای تخمین مدل از داده‌های روزانه ۳۱ ژانویه ۱۹۹۴ تا ۴ می ۱۹۹۹، و برای پیش‌بینی خارج از نمونه از داده‌های ۵ می ۱۹۹۹ تا ۶ ژوئن ۲۰۰۰ استفاده نمودند. سپس آن‌ها نتایج پیش‌بینی مدل را با پیش‌بینی روش‌های تجاری مانند خرید و نگهداری، انتظارات تطبیقی ساده^۳ و سبد میانگین متحرک^۴ (BMA) با استفاده از معیارهای مختلف مانند نسبت شارپ^۵ و آماره t مربوط به سود سهام مقایسه نموده و برتری مدل شبکه عصبی را نشان داده‌اند.^۶

ایم^۷ (۲۰۰۲) با استفاده از مدل شبکه عصبی بازدهی شاخص روزانه سهام برزیل را پیش‌بینی نموده و نتایج پیش‌بینی را با استفاده از معیارهای RMSE، MAE و آزمون چونگ و هندری^۸ با نتایج پیش‌بینی مدل‌های ARMA-GARCH و ساختاری مقایسه نموده و برتری مدل شبکه عصبی مصنوعی را نشان داده است. وی برای برآورد مدل از داده‌های روزانه این شاخص از ۳۰ جولای ۱۹۹۴ تا ۳۰ ژوئن ۱۹۹۸ استفاده نموده است.^۹

قاسمی، اسدپور و شاصادقی (۱۳۷۷) با استفاده از داده‌های ماهیانه شیر از اول سال ۱۳۷۱ تا پایان سال ۱۳۷۶ مدل‌های شبکه عصبی و ARIMA را برآورد نموده و سپس از آن‌ها برای پیش‌بینی قیمت ۱۲ ماه بعد استفاده نموده‌اند. آن‌ها با استفاده از معیارهای میانگین مربعات خطا و قدرمطلق درصد خطا نشان داده‌اند که مدل شبکه عصبی از قدرت پیش‌بینی

1. Maddala & In-Moo (1998).
2. Dunis & Jalilov.
3. Naïve Adaptive Expectation.
4. Basket of Moving Average.
5. Sharp ratio.
6. Dunis & Jalilov (2001).
7. Yim.
8. Chong and Hendry encompassing test.
9. Stock & Watson.

بیشتری نسبت به مدل ARIMA برخوردار است. مشیری (۱۳۸۰) با استفاده از مدل‌های ساختاری، مدل‌های سری‌زمانی و شبکه عصبی، تورم در ایران را پیش‌بینی نموده است. وی برای برآورد مدل‌ها از داده‌های تورم سال ۱۳۳۸ تا ۱۳۷۱ استفاده نموده و تورم در دوره ۱۳۷۶-۱۳۷۲ را پیش‌بینی نموده است. وی با استفاده از معیارهای MAE، RMSE و آماره U توانایی پیش‌بینی بیشتر مدل شبکه عصبی را نسبت به سایر مدل‌ها نشان داده است.

مشیری و فروتن (۱۳۸۳) با استفاده از مدل‌های شبکه عصبی، ARIMA و GARCH قیمت‌های آتی نفت را برای یک دوره زمانی ۷۰۰ روزه پیش‌بینی نموده و نتایج را با استفاده از معیارهای MAE، MSE و RMSE مقایسه نموده و نشان داده‌اند که مدل شبکه عصبی از قدرت پیش‌بینی بیشتری نسبت به سایر مدل‌ها برخوردار است. ایشان همچنین با استفاده از آماره دیلدا و ماریانو نشان دادند که تفاوت معنی‌داری در دقت پیش‌بینی مدل شبکه عصبی با دو مدل دیگر وجود دارد.

۳. روش‌های ارزیابی دقت مدل‌های پیش‌بینی

بحث چگونگی ارزیابی دقت پیش‌بینی مدل‌های اقتصادی در دهه‌های اخیر توجه بسیاری از اقتصاددانان را به خود جلب کرده است و مطالعات نظری و تجربی متعددی در این زمینه صورت گرفته است. در این تحقیق از ریشه میانگین مجذور خطا (RMSE)^۱، میانگین قدرمطلق خطا (MAE)^۲ و معیار یو-تایل (Thiel-U) به عنوان شاخص‌های خطای پیش‌بینی و آزمون دیلدا-ماریانو^۳ (DM-test) به عنوان آزمون آماری مقایسه شاخص‌های خطای پیش‌بینی استفاده می‌شود.

معیارهای خطای پیش‌بینی هر چه کمتر باشند نمایانگر پیش‌بینی دقیق‌تر هستند. معیار U-Thiel خطای پیش‌بینی مدل مورد نظر را نسبت به خطای پیش‌بینی مدل ساده (naive) یا AR(1) اندازه‌گیری می‌کند در نتیجه عدد کوچک‌تر از یک برای این نسبت به معنای

1. Root Mean Squared Error.

2. Mean Absolute Error.

3. Diebold-Mariano Test.

پیش‌بینی دقیق‌تر مدل مورد نظر نسبت به $AR(1)$ است.

آزمون دیبلد-ماریانو (DM-test) قیود محدود‌کننده بسیار اندکی در مورد فرایند خطاها و تابع خطا دارد و آماره آن به صورت زیر محاسبه می‌شود^۱:

فرض کنید e_{ij} خطای پیش‌بینی تخمینی مدل j^{th} باشد و $g(e_{ij})$ تابع خطای مورد نظر باشد. فرضیه صفر برابری دقت پیش‌بینی برای دو پیش‌بینی مختلف عبارت است از

$$d_t = [g(e_{it}) - g(e_{jt})] \quad \text{که} \quad E(d_t) = 0 \quad \text{یا} \quad E[g(e_{it})] = E[g(e_{jt})]$$

فرض کنید $\{d_t\}_{t=1}^T$ سری تفاضل‌گیری شده تابع خطا می‌باشد. اگر این سری مانای ضعیف و دارای حافظه کوتاه‌مدت باشد می‌توان نشان داد آماره آزمون فرضیه فوق برای نمونه‌های بزرگ دارای توزیع نرمال استاندارد خواهد بود. این آماره عبارتست از:

$$DM = \frac{\bar{d}}{\sqrt{\frac{2\pi \hat{f}_d(0)}{T}}}$$

که در این رابطه \bar{d} میانگین سری تفاضلی تابع خطا در نمونه می‌باشد. همچنین $\frac{2\pi \hat{f}_d(0)}{T}$ واریانس سری $\{d_t\}_{t=1}^T$ می‌باشد. در این رابطه $\hat{f}_d(0)$ چگالی طیفی مشتق خطا در فرکانس صفر^۲ می‌باشد. قرار گرفتن مقدار این آماره در ناحیه بحرانی به معنی وجود تفاوت معنی‌دار در قدرت پیش‌بینی مدل‌های مورد مقایسه می‌باشد.

۴. داده‌ها

در این تحقیق برای پیش‌بینی شاخص بازدهی بورس اوراق بهادار تهران از شاخص‌های بازدهی روزانه و هفتگی کل قیمت سهام تهران (TEPIX) در بازه زمانی اول ۱۳۷۷ تا پایان ۱۳۸۲ استفاده می‌شود. بنابراین حجم نمونه‌های مورد استفاده در تحقیق ۱۴۵۲ مشاهده برای شاخص روزانه و ۳۰۳ مشاهده برای شاخص هفتگی می‌باشد. با استفاده از ۷۵٪ این داده‌ها مدل‌های پیش‌بینی مختلف برآورده شده و از ما بقی اطلاعات برای پیش‌بینی سری‌ها و

1. Diebold & Mariano (1995).

2. Spectral density of the loss differential at frequency 0.

مقایسه دقت پیش‌بینی‌ها استفاده می‌شود.

شاخص‌های بازدهی روزانه و هفتگی سهام تهران به صورت درصد تغییر در شاخص‌های قیمت (TEPIX) تعریف و محاسبه شده‌اند.

۵. نتایج پیش‌بینی

برای پیش‌بینی از متدولوژی باکس-جنکینز و از روش پیش‌بینی پویا^۱ استفاده شده است.

۵-۱. پیش‌بینی بازدهی روزانه و هفتگی TEPIX با استفاده از مدل ARIMA

برای پیش‌بینی با مدل ARIMA ابتدا مدل مناسب با استفاده از ۷۵٪ مشاهدات برآورد شد. برای برازش مدل ARIMA ابتدا مانایی سری‌ها با استفاده از آزمون دیکی-فولر تعمیم یافته (ADF) و نمودارهای خودهمبستگی (AC) و خودهمبستگی جزئی (PAC) بررسی شد. برای آزمون (ADF) وقفه‌های مناسب با استفاده از معیار آکایک (AIC) تعیین شدند. آزمون‌های فوق وجود ریشه واحد در سری‌ها را در سطح ۱٪ تأیید نکردند. سپس برای برازش مدل $ARMA(p,q)$ ، مرتبه‌های خودرگرسیون (AR) و میانگین متحرک (MA) با استفاده از نمودارهای AC و PAC تعیین شدند. مدل $ARMA(2,2)$ بر سری زمانی شاخص بازدهی روزانه سهام و فرایند $ARMA(3,3)$ بر سری زمانی شاخص بازدهی هفتگی سهام برآورد شد. برای مطمئن شدن از مناسب بودن مدل برازش شده، ریشه واحد بودن پسماندهای مدل فوق با استفاده از آزمون ADF بررسی شد، این آزمون عدم وجود ریشه واحد در پسماندهای مدل‌های فوق و در نتیجه مانایی آن‌ها را نشان داد و البته سایر آزمون‌های کنترل تشخیصی برای مدل‌های مختلف انجام شده که در پیوست‌های ۱ و ۲ به ترتیب برای شاخص روزانه و هفتگی ارائه شده است. سپس با استفاده از این مدل‌ها پیش‌بینی خارج از نمونه صورت گرفت. بعد از پیش‌بینی با این مدل، معیارهای اندازه‌گیری خطای پیش‌بینی محاسبه شده که به ترتیب برای شاخص بازدهی روزانه و هفتگی در قالب

1. Dynamic.

جداول (۱) و (۲) بیان شده‌اند.

۲-۵. پیش‌بینی بازدهی روزانه و هفتگی TEPIX با استفاده از مدل GARCH

به منظور پیش‌بینی با مدل GARCH ابتدا مدل GARCH(1,1) بر بازدهی روزانه و هفتگی TEPIX برازش شد و سپس مقدار این شاخص‌ها با استفاده از این مدل پیش‌بینی شدند و دقت پیش‌بینی این مدل با استفاده از معیارهای مختلف با سایر مدل‌های پیش‌بینی مورد استفاده در این تحقیق مقایسه شد. معیارهای اندازه‌گیری خطای پیش‌بینی به ترتیب برای شاخص بازدهی روزانه و هفتگی در قالب جداول (۱) و (۲) بیان شده‌اند.

۳-۵. پیش‌بینی بازدهی روزانه و هفتگی TEPIX با استفاده از مدل ARFIMA

برای پیش‌بینی با این مدل ابتدا پارامترهای مدل مذکور (از جمله پارامتر تفاضل‌گیری، d) با استفاده از روش حداکثر درست‌نمایی برآورد شد و سپس پیش‌بینی خارج از نمونه انجام شد. مدل ARFIMA(2,d,2) بر شاخص بازدهی روزانه ($\hat{d} = 0.08$ معنی‌دار در سطح ۱٪) و مدل ARFIMA(3,d,3) بر شاخص بازدهی هفتگی ($\hat{d} = 0.35$ معنی‌دار در سطح ۱٪) برازش شدند. معیارهای اندازه‌گیری خطای پیش‌بینی به ترتیب برای شاخص بازدهی روزانه و هفتگی در قالب جداول (۱) و (۲) بیان شده‌اند. برای برآورد و پیش‌بینی این مدل از نرم‌افزار OX و جعبه‌ابزار OXPACK استفاده شد.

۴-۵. پیش‌بینی بازدهی روزانه و هفتگی TEPIX با استفاده از مدل ANN

به منظور پیش‌بینی شاخص بازدهی روزانه از شبکه عصبی با دو نرون در لایه ورودی (به علت آنکه این سری از فرآیند AR(2) تبعیت می‌کند) که نماینده متغیرهای ورودی شاخص بازدهی روزانه با وقفه‌های یک و دو می‌باشد، استفاده شد. در مورد پیش‌بینی شاخص بازدهی هفتگی از سه نرون در لایه ورودی استفاده شده است (به علت آنکه این سری از فرآیند AR(3) تبعیت می‌کند). در لایه میانی از سه نرون و تابع فعال‌سازی تانژانت سیگموید استفاده شده و در لایه خروجی از تابع همانی استفاده شده است. برای پیش‌بینی این سری‌ها نرم‌افزار MATLAB بکار گرفته شده است. معیارهای اندازه‌گیری خطای

پیش‌بینی به ترتیب برای شاخص بازدهی روزانه و هفتگی در جدول (۱) بیان شده‌اند.

جدول ۱- نتایج پیش‌بینی شاخص بازدهی TEPIX

models forecast performance	ARMA	GARCH	ARFIMA	ANN
روزانه RMSE	0.0079	0.008	0.008	0.0079
هفتگی RMSE	0.026	0.026	0.026	0.025
روزانه MAE	0.0052	0.0053	0.0053	0.0052
هفتگی MAE	0.018	0.017	0.018	0.017
U-Thiel روزانه	0.86	0.91	0.87	0.85
U-Thiel هفتگی	0.75	0.73	0.8	0.69

۶. ارزیابی دقت مدل‌های پیش‌بینی

معیارهای ارزیابی دقت پیش‌بینی برای مدل‌های مختلف در جدول (۱) ارائه شده‌اند. طبق این نتایج، شاخص‌های خطای پیش‌بینی توسط مدل‌های مختلف بسیار به یکدیگر نزدیک هستند و مدل ANN شاخص‌های خطای کمتر یا برابر با شاخص‌های خطای سایر مدل‌ها تولید کرده است. طبق معیار U-thiel نیز عملکرد پیش‌بینی مدل ANN نسبت به AR(1) بهتر از سایر مدل‌ها می‌باشد.

برای بررسی این مسئله که آیا تفاوت در دقت پیش‌بینی مدل‌های مختلف از لحاظ آماری معنی‌دار است یا خیر آماره دیلید-ماریانو برای حالت‌های مختلف مقایسه شد. نتایج این آزمون در جدول (۲) ارائه شده است:

جدول ۲: مقادیر آماره دیلید-ماریانو برای حالت‌های مختلف برای شاخص بازدهی روزانه TEPIX

MODELS	ARMA	GARCH	ARFIMA	ANN
روزانه ARMA		-0.2	-0.19	-0.23
هفتگی ARMA		0.14	-0.13	0.2
روزانه GARCH	-0.2		0.2	-0.2
هفتگی GARCH	0.14		-0.13	0.2
روزانه ARFIMA	-0.19	0.2		-0.23
هفتگی ARFIMA	-0.13	-0.13		0.18
روزانه ANN	-0.23	-0.2	-0.23	
هفتگی ANN	0.2	0.2	0.18	

همانگونه که از نتایج گزارش شده در جدول (۲) آشکار است، هیچ یک از مقادیر آماره دیلد-ماریانو برای حالت‌های مختلف در سطوح مختلف معنی داری نمی‌باشند. در نتیجه دقت مدل‌های پیش‌بینی از نظر آماری تفاوت معنی دار ندارند.

جمع‌بندی و ملاحظات

به دلیل اهمیت پیش‌بینی متغیرهای کلان اقتصادی امروزه اکثر دولت‌ها و بانک‌های مرکزی در اتخاذ و اجرای سیاست‌هایشان علاوه بر توجه بر وضع موجود، پیش‌بینی‌های کوتاه‌مدت و بلندمدت متغیرهای اصلی اقتصاد را در نظر می‌گیرند. در میان متغیرهای اقتصادی، قیمت‌های بازار سهام به علت تغییرات بسیار وسیع، شدید و ناگهانی و تأثیرپذیری آن‌ها از بسیاری عوامل اقتصادی، اجتماعی، سیاسی، و حتی طبیعی یکی از مشکل‌ترین و پیچیده‌ترین موارد برای پیش‌بینی به حساب می‌آید. در واقع، یکی از نظریه‌های معروف اقتصادی در زمینه بازارهای مالی نظریه پیش‌بینی ناپذیری تغییرات قیمت‌های سهام که در آماره به نظریه گام تصادفی معروف است می‌باشد. مدل‌های پیش‌بینی که برای قیمت‌های سهام طراحی شده‌اند در واقع به عنوان چالشی در مقابل نظریه فوق مطرح هستند و سعی دارند نشان دهند که می‌توان علی‌رغم پیچیدگی‌های بسیار در روند قیمت‌ها، روند آتی آن‌ها را با خطاهای قابل قبولی پیش‌بینی نمود. از جمله این مدل‌ها مدل‌های غیرخطی مانند GARCH و مدل‌های غیرخطی انعطاف‌پذیر مانند مدل‌های شبکه‌های عصبی مصنوعی (ANN) و یا میانگین متحرک خود همبسته با درجه انباشتگی شکسته (ARFIMA) هستند. مدل‌های فوق نشان داده‌اند که در زمینه پیش‌بینی متغیرهایی که از روند بسیار پیچیده‌ای برخوردار هستند نسبتاً موفق می‌باشند.

در این تحقیق، ما برای پیش‌بینی شاخص قیمت‌های سهام تهران (TEPIX) از مدل‌های خطی و غیرخطی که نسبتاً جدید هستند استفاده کرده‌ایم. مشیری و مروت (۱۳۸۴) نشان داده‌اند که قیمت‌های سهام تهران ممکن است از یک روند آشوبی پیروی کند، در نتیجه انتظار می‌رود که مدل‌های غیرخطی فوق بتوانند دقت مناسبی در پیش‌بینی آن داشته باشند. نتایج پیش‌بینی‌های پویا که توسط مدل‌های ARIMA، GARCH، ARFIMA و ANN انجام

شد نشان دادند که مدل ANN از دقت پیش‌بینی مناسبتری برخوردار است. از آن جا که نتایج پیش‌بینی در بسیاری موارد نزدیک به هم بودند از آزمون آماری تفاوت در خطای پیش‌بینی استفاده شد که طبق نتایج آن، خطاهای پیش‌بینی بدست آمده تفاوت معنی‌داری با یکدیگر نداشتند. با توجه به این که مدل‌های محاسباتی انعطاف پذیر مانند شبکه عصبی و یا مدل‌های حافظه بلندمدت نیاز به آمار بسیار زیاد دارند، شاید استفاده از بازه آماری وسیع‌تر در تفاوت معنی‌دار پیش‌بینی‌ها تأثیر داشته باشد. به هر حال با توجه به نتایج به دست آمده می‌توان استفاده از مدل‌های غیرخطی مانند ARFIMA و ANN را برای پیش‌بینی قیمت‌های سهام تهران نیز به پژوهشگران توصیه نمود.

منابع

- اصغری اسکویی، محمدرضا (۱۳۸۱)؛ "کاربرد شبکه عصبی در پیش‌بینی سری‌زمانی"، مجموعه مقاله‌های اولین همایش معرفی و کاربرد مدل‌های ناخطی پویا و محاسباتی در اقتصاد، دانشگاه علامه طباطبائی، دانشکده اقتصاد، مرکز تحقیقات اقتصاد ایران، صفحه ۱۴۵-۱۲۱.
- قاسمی، ع. ح. اسدپور م. شاصادقی (۱۳۷۷)؛ "کاربرد شبکه عصبی در پیش‌بینی سری‌های زمانی و مقایسه آن با مدل ARIMA"، پژوهشنامه بازرگانی، صفحه ۱۱۹-۷۸.
- قدیمی، م. و سعید مشیری (۱۳۸۱)؛ "مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی"، مجموعه مقاله‌های اولین همایش معرفی و کاربرد مدل‌های ناخطی پویا و محاسباتی در اقتصاد، دانشگاه علامه طباطبائی، دانشکده اقتصاد، مرکز تحقیقات اقتصاد ایران.
- مشیری، سعید (۱۳۸۰)؛ "پیش‌بینی تورم ایران با استفاده از مدل‌های ساختاری، سری‌های زمانی و شبکه‌های عصبی"، مجله تحقیقات اقتصادی، شماره ۵۸، صفحات ۱۸۴-۱۴۷.
- مشیری، سعید و فائزه فروتن (۱۳۸۳)؛ "آزمون آشوب و پیش‌بینی قیمت‌های نفت خام"، فصلنامه پژوهش‌های اقتصادی ایران، زمستان، شماره ۲۱، صفحه ۹۰-۶۷.
- مشیری، سعید و حبیب مروت (۱۳۸۴)؛ "آزمون‌های آشوبی برای شاخص قیمت‌های سهام تهران"، فصلنامه پژوهش‌های اقتصادی ایران، در حال چاپ.
- Baillie, R. T., (1996); "Long Memory Process and Fractional Integration in Economics", *Journal of Econometrics*, No. 73, pp. 5-59.
- Baillie, R. T., M. L. King, (1996); "Fractional Differencing and Long Memory Process", *Journal of Econometrics*, No. 73, pp. 1-3.
- Barkoulas, J. T, C.F.Baum, N. Travlos, (1997); "Long Memory in the Greek Stock Market", *Working Paper*, Boston College, Chestnut Hill.
- Diebold, F. X., R. S. Mariano, (1995); "Comparing Predictive Accuracy", *Journal of Business & Economic Statistics*, 13 (3), pp. 253-263.

- Dunis, C.L, J. Jalilov (2001); "Neural Network Regression and Alternative Forecasting Techniques for Predicting Financial Variables", *Working Paper*, Liverpool Business School and CIBEF.
- Granger, C. w. J., P. Newbold (1986); "Forecasting Economic Time Series", *Academic Press, INC*.
- Guerard, J.B., D.D. Thomakos, T. Wang. (2002); "Forecasting Realized Future Volatility", *Working paper*.
- Jungeiliges, J. A. (1996); *Operational Characteristics of White's Test for Neglected Nonlinearities, Nonlinear Dynamics and Economics*, Cambridge University Press, pp. 219-266.
- Leung, M. T., H., Daouk, A. Chen, (2000); "Forecasting Stock Indices: a Comparison of Classification and Level Estimate Models", *International Journal of Forecasting*, No. 16, pp. 173-190.
- Maddala, G. S., K. In-Moo (1998); *Unit Roots, Co integration, and structural Change*, Cambridge University Press.
- Oomen, R.C.A. (2001); "Using High Frequency Stock Market Index Data to Calculate, Model and Forecast Realized Volatility", *Working Paper*, European University Institute, Department of Economics, Viadei Rocchetinni, Italy.
- Peters. E. Edgar. (1992); *Fractal Market Analysis: Applying Chaos Theory to Investment and Economics*, John Willy & Sons INC.
- Poon, S., C. Granger (2003); "Forecasting Volatility in Financial Markets: A Review", *Working Paper*.
- Stock, J. H., M. E. Watson, "A Comparison of Linear and Nonlinear Univariate Models for Forecasting Macroeconomic Time Series", *Working Paper*.
- Yim, Juliana. (2002); "A comparison of neural networks with time series models for forecasting returns on a stock market index", *Working Paper*, School of Economics and Finance.

پیوست (۱)

نتایج آزمون‌های کنترل تشخیصی مدل‌های مورد استفاده برای شاخص روزانه

آماره‌های ADF و انگل محاسبه شده برای مدل‌های مختلف برازش شده بر شاخص روزانه

نام سری زمانی	مقدار آماره ADF محاسبه شده	مقدار آماره آزمون اثرات (F) ARCH
D(log(TEPIX))	-۱۸٫۹۵***	
پسماندهای مدل ARMA	-۳۱٫۷۲***	۳۵۴٫۷۱***
پسماندهای مدل GARCH	-۳۲٫۱۶***	۰٫۲۴۳
پسماندهای مدل ARFIMA	-۳۴٫۰۷***	۳۳۶٫۶۵***

نمودار خود همبستگی و خود همبستگی جزئی سری D(LOG(TEPIX))

Date: 07/14/06 Time: 22:50

Sample: 1 1089

Included observations: 1088

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.107	0.107	12.525	0.000	
2	0.186	0.177	50.415	0.000	
3	0.079	0.046	57.272	0.000	
4	0.123	0.084	73.902	0.000	
5	0.095	0.060	83.728	0.000	
6	0.119	0.074	99.363	0.000	
7	0.116	0.071	114.02	0.000	
8	0.095	0.038	123.86	0.000	
9	0.102	0.048	135.40	0.000	
10	0.121	0.069	151.45	0.000	
11	0.093	0.032	161.04	0.000	
12	0.062	-0.005	165.28	0.000	
13	0.043	-0.017	167.28	0.000	
14	0.106	0.060	179.60	0.000	
15	0.083	0.034	187.19	0.000	
16	0.021	-0.048	187.70	0.000	
17	0.053	0.002	190.75	0.000	
18	0.030	-0.008	191.78	0.000	
19	0.054	0.013	194.99	0.000	
20	0.059	0.024	198.90	0.000	

نمودار خود همبستگی و خود همبستگی جزئی پسماندهای مدل ARMA

Date: 07/14/06 Time: 23:46
 Sample: 4 1089
 Included observations: 1086
 Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
0.041	0.041	1.8593			
0.009	0.007	1.9404			
0.020	0.019	2.3667	0.124		
-0.022	-0.024	2.9084	0.234		
0.038	0.039	4.4588	0.216		
0.001	-0.002	4.4605	0.347		
0.064	0.065	9.0128	0.109		
-0.008	-0.015	9.0754	0.169		
0.052	0.054	12.001	0.101		
0.044	0.036	14.172	0.077		
0.046	0.047	16.502	0.057		
-0.013	-0.026	16.701	0.081		
-0.011	-0.008	16.844	0.113		
0.055	0.049	20.218	0.063		
0.046	0.045	22.527	0.048		
-0.036	-0.052	23.964	0.046		
0.013	0.012	24.150	0.063		
-0.016	-0.023	24.423	0.081		
0.021	0.023	24.892	0.097		
0.027	0.013	25.673	0.107		
-0.071	-0.078	31.214	0.038		

نمودار خود همبستگی و خود همبستگی جزئی پسماندهای مدل GARCH

Date: 07/14/06 Time: 23:49
 Sample: 4 1089
 Included observations: 1086
 Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
0.143	0.143	22.158			
0.043	0.023	24.203			
0.014	0.005	24.428	0.000		
-0.007	-0.011	24.481	0.000		
0.024	0.027	25.123	0.000		
-0.017	-0.024	25.427	0.000		
0.040	0.045	27.194	0.000		
-0.002	-0.014	27.199	0.000		
0.041	0.042	29.034	0.000		
0.029	0.016	29.961	0.000		
0.028	0.022	30.826	0.000		
0.017	0.005	31.140	0.001		
-0.002	-0.003	31.143	0.001		
0.031	0.027	32.187	0.001		
0.045	0.040	34.426	0.001		
-0.018	-0.035	34.765	0.002		
0.040	0.045	36.499	0.001		
0.022	0.009	37.023	0.002		
0.014	0.005	37.226	0.003		
0.001	-0.007	37.226	0.005		
-0.058	-0.059	40.937	0.002		

نمودار خود همبستگی و خود همبستگی جزئی پسماندهای مدل ARFIMA

Date: 07/14/06 Time: 23:54

Sample: 1 1089

Included observations: 1088

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1		-0.028	-0.028	0.8472	0.357
2		0.009	0.009	0.9413	0.625
3		-0.008	-0.008	1.0114	0.799
4		-0.024	-0.025	1.6508	0.800
5		0.023	0.022	2.2252	0.817
6		-0.004	-0.002	2.2391	0.896
7		0.053	0.053	5.3646	0.616
8		-0.015	-0.013	5.6254	0.689
9		0.041	0.041	7.4758	0.588
10		0.035	0.038	8.8619	0.545
11		0.038	0.042	10.434	0.492
12		-0.020	-0.021	10.865	0.541
13		-0.018	-0.016	11.225	0.592
14		0.049	0.047	13.903	0.457
15		0.040	0.046	15.711	0.401
16		-0.044	-0.050	17.822	0.334
17		0.012	0.007	17.986	0.390
18		-0.021	-0.021	18.468	0.425
19		0.019	0.018	18.869	0.465
20		0.027	0.021	19.654	0.480
21		-0.070	-0.075	25.033	0.246
22		-0.055	-0.064	28.456	0.161

پیوست (۲)

نتایج آزمون‌های کنترل تشخیصی مدل‌های مورد استفاده برای شاخص هفتگی

آماره‌های ADF و انگل محاسبه شده برای مدل‌های مختلف برازش شده بر شاخص

هفتگی

نام سری زمانی	مقدار آماره ADF محاسبه شده	مقدار آماره آزمون اثرات ARCH (F)
D(log(TEPIX))	-۱۱.۵۱ ^{***}	
پسماندهای مدل ARMA	-۱۵.۲۶ ^{***}	۱۹.۴ ^{***}
پسماندهای مدل GARCH	-۳۲.۱۶ ^{***}	۰.۹
پسماندهای مدل ARFIMA	-۱۵.۲۶ ^{***}	۲۳.۵۴ ^{***}

نمودار خود همبستگی و خود همبستگی جزئی سری $D(\text{LOG}(\text{TEPIX}))$

Date: 07/15/06 Time: 00:19

Sample: 1 227

Included observations: 226

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.291	0.291	19.453	0.000
		2 0.220	0.147	30.539	0.000
		3 0.256	0.178	45.725	0.000
		4 0.072	-0.069	46.920	0.000
		5 0.123	0.065	50.454	0.000
		6 0.117	0.038	53.677	0.000
		7 0.047	-0.008	54.192	0.000
		8 0.021	-0.044	54.301	0.000
		9 0.049	0.030	54.881	0.000
		10 0.001	-0.022	54.882	0.000
		11 0.068	0.072	55.984	0.000
		12 0.074	0.032	57.310	0.000
		13 -0.009	-0.047	57.331	0.000
		14 0.045	0.019	57.815	0.000
		15 -0.062	-0.101	58.757	0.000
		16 -0.087	-0.060	60.628	0.000
		17 -0.026	0.001	60.795	0.000
		18 0.061	0.137	61.720	0.000
		19 -0.085	-0.117	63.530	0.000
		20 -0.032	-0.004	63.785	0.000
		21 0.106	0.145	66.607	0.000
		22 -0.048	-0.053	67.178	0.000

نمودار خود همبستگی و خود همبستگی جزئی پسماندهای مدل ARMA

Date: 07/15/06 Time: 21:11

Sample: 1 227

Included observations: 225

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.088	0.088	1.7808	0.182
		2 -0.011	-0.018	1.8061	0.405
		3 -0.018	-0.015	1.8779	0.598
		4 -0.079	-0.077	3.3093	0.507
		5 -0.022	-0.009	3.4223	0.635
		6 -0.090	-0.091	5.2917	0.507
		7 -0.003	0.011	5.2934	0.624
		8 -0.081	-0.093	6.8394	0.554
		9 -0.097	-0.088	9.0520	0.432
		10 -0.000	-0.003	9.0521	0.527
		11 0.033	0.026	9.3192	0.592
		12 -0.016	-0.048	9.3815	0.670
		13 0.025	0.016	9.5331	0.732
		14 0.036	0.014	9.8430	0.774
		15 -0.176	-0.199	17.377	0.297
		16 -0.060	-0.041	18.248	0.310
		17 -0.062	-0.075	19.184	0.318
		18 0.018	0.006	19.263	0.376
		19 -0.067	-0.107	20.363	0.373
		20 -0.101	-0.110	22.891	0.294
		21 0.062	0.017	23.865	0.300
		22 -0.058	-0.090	24.698	0.312

نمودار خود همبستگی و خود همبستگی جزئی پسماندهای مدل GARCH

Date: 07/15/06 Time: 21:14
 Sample: 1 227
 Included observations: 223

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.030	0.030	0.2050	0.651
		2 0.015	0.014	0.2572	0.879
		3 -0.013	-0.014	0.2983	0.960
		4 -0.067	-0.066	1.3229	0.857
		5 0.038	0.043	1.6622	0.894
		6 -0.066	-0.067	2.6550	0.851
		7 0.032	0.034	2.8985	0.894
		8 -0.044	-0.048	3.3472	0.911
		9 -0.069	-0.063	4.4569	0.879
		10 0.017	0.013	4.5233	0.921
		11 0.049	0.060	5.0990	0.926
		12 0.003	-0.016	5.1014	0.955
		13 0.032	0.032	5.3518	0.967
		14 0.050	0.050	5.9418	0.968
		15 -0.153	-0.162	11.600	0.709
		16 -0.038	-0.028	11.944	0.748
		17 -0.063	-0.051	12.901	0.743
		18 0.056	0.055	13.659	0.751
		19 -0.055	-0.075	14.409	0.759
		20 -0.096	-0.077	16.681	0.674
		21 0.093	0.078	18.846	0.595
		22 -0.091	-0.078	20.896	0.527

نمودار خود همبستگی و خود همبستگی جزئی پسماندهای مدل ARFIMA

Date: 07/15/06 Time: 21:17
 Sample: 1 227
 Included observations: 226

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.006	-0.006	0.0080	0.929
		2 -0.024	-0.024	0.1397	0.933
		3 0.066	0.066	1.1454	0.766
		4 -0.005	-0.005	1.1510	0.886
		5 0.014	0.017	1.1937	0.945
		6 -0.013	-0.018	1.2344	0.975
		7 0.074	0.075	2.5125	0.926
		8 -0.061	-0.064	3.4006	0.907
		9 -0.039	-0.034	3.7659	0.926
		10 0.040	0.027	4.1481	0.940
		11 0.033	0.042	4.4108	0.956
		12 0.008	0.011	4.4274	0.974
		13 0.042	0.044	4.8522	0.978
		14 0.056	0.047	5.6215	0.975
		15 -0.133	-0.128	9.9407	0.823
		16 -0.020	-0.023	10.039	0.865
		17 -0.041	-0.064	10.450	0.884
		18 0.069	0.086	11.614	0.867
		19 -0.045	-0.044	12.114	0.881
		20 -0.097	-0.085	14.486	0.805
		21 0.101	0.086	17.055	0.708
		22 -0.063	-0.036	18.057	0.703