

ارزیابی پیش‌بینی پذیری قیمت طلا و مقایسه پیش‌بینی روش‌های خطی و غیرخطی

سید عزیز آرمن*

دانشیار گروه اقتصاد دانشگاه شهید چمران اهواز، Saarman2@yahoo.com

علی رئوفی

دانشجوی کارشناسی ارشد اقتصاد دانشگاه شهید چمران اهواز، Ali_r1367@yahoo.com

تاریخ دریافت: ۹۲/۴/۱۰ تاریخ پذیرش: ۹۲/۷/۱۰

چکیده

در این مقاله قابلیت پیش‌بینی بازده روزانه قیمت جهانی طلا از تاریخ 2011/07/25 تا 2012/12/17 مورد بررسی قرار گرفته است. بدین منظور ابتدا با استفاده از آزمون براک-دیکرت - شاینکمن (BDS) به بررسی خطی، غیرخطی و آشوبناک بودن سری مورد مطالعه پرداخته شده است. نتایج تحقیق فرض تصادفی بودن سری مورد مطالعه را رد می‌کند که شاهدهی بر پیش‌بینی پذیر بودن بازده روزانه قیمت طلاست. همچنین فرضیه عدم وجود رابطه غیرخطی در جملات پسماند مدل خطی رد می‌شود که نشان از وجود رفتار غیرخطی در سری مورد بررسی است. برای پیش‌بینی بازده روزانه قیمت طلا یک مدل عصبی فازی ANFIS طراحی گردیده و نتایج آن با استفاده از معیارهای مختلف مورد ارزیابی قرار گرفته است. همچنین نتایج با نتایج دو مدل خطی ARMA و غیرخطی GARCH مقایسه شد که مطابق انتظار، مدل غیرخطی ANFIS پیش‌بینی بهتری از سایر مدل‌های رقیب داشت. در نهایت با استفاده از آماره مورگان - گرنجر - نیبولد (MGN) معنی‌داری اختلاف پیش‌بینی مدل‌ها مورد بررسی قرار گرفت. نتایج حاکی از معنی‌دار بودن اختلاف پیش‌بینی مدل‌های غیرخطی نسبت به مدل خطی ARMA است.

واژه‌های کلیدی: پیش‌بینی پذیری، شبکه عصبی فازی، ANFIS، آزمون BDS، روش‌های غیر خطی، قیمت طلا.

طبقه‌بندی JEL: C53, C58, C45, G17.

1- مقدمه

قیمت طلا و روند تغییرات آن در اقتصاد ملی و اقتصاد جهانی از اهمیت قابل ملاحظه‌ای برخوردار است. از آنجا که شناخت رفتار قیمت طلا به دلیل پیچیدگی‌های ناشی از تأثیر عوامل متعدد و نوسانات گسترده تا حدی مشکل است، اغلب برای پیش‌بینی آن از الگوهای خودرگرسیون تک متغیره استفاده می‌شود. در این الگوها مقدار متغیر مورد پیش‌بینی به صورت تابعی از مقادیر گذشته آن متغیر و یک «جزء اخلال» در نظر گرفته می‌شود که این جزء، طبق نگرش مرسوم، تصادفی فرض می‌شود و پژوهشگر به دنبال کشف بخش تصادفی و جداسازی آن از بخش غیر تصادفی است. بر اساس نظریه آشوب¹، ممکن است که این جزء به ظاهر تصادفی از یک فرآیند معین² غیرخطی پیروی کند و به وسیله یک معادله یا سیستم معادلات معین قابل تصریح باشد. در واقع، نظریه آشوب در جستجوی نظم در رفتار به ظاهر تصادفی برخی سیستم‌های پویا و غیرخطی معین است. بر این اساس، می‌توان تغییرات نامنظم روند برخی متغیرهای مالی نظیر بازده شاخص سهام، قیمت طلا و... را نتیجه وجود ساختار آشوبناک در آن‌ها دانست و با بکارگیری روش‌های مناسب، امکان پیش‌بینی دقیق‌تر این متغیرها را فراهم نمود.

روش‌های میانگین متحرک، هموارسازی نمایی³ و میانگین متحرک خودرگرسیونی انباشته (ARIMA)⁴ از جمله روش‌های خطی مرسوم هستند که در آن‌ها پیش‌بینی مقادیر آینده به عنوان تابعی خطی از مشاهدات گذشته فرض می‌شود. این روش‌ها به دلیل سادگی نسبی در فهم و بکارگیری، بسیار پرکاربرد بوده‌اند. از طرف دیگر برای رفع مشکل محدودیت خطی بودن مدل، چندین نوع از مدل‌های غیرخطی پیشنهاد شده است که از جمله مهم‌ترین آن‌ها می‌توان به مدل‌های خانواده واریانس ناهمسانی شرطی خودرگرسیونی (ARCH)⁵، دو خطی⁶ و خودرگرسیو آستانه‌ای (TAR)⁷ اشاره نمود. هر چند مدل‌های مذکور بهبودهایی در نتایج پیش‌بینی به وجود آورده‌اند، اما این گونه مدل‌ها تنها برای

¹ Chaos Theory

² Deterministic

³ Exponential Smoothing

⁴ Autoregressive Integrated Moving Average

⁵ Autoregressive Conditional Heteroskedasticity

⁶ Bilinear

⁷ Threshold Auto Regressive

الگوهای غیرخطی خاصی طراحی شده‌اند (ژانگ و هو،¹ 2004) و قادر به شناسایی انواع سری‌های زمانی غیرخطی نیستند. از این رو روش‌های جدیدی از پیش‌بینی به نام روش شبکه‌های عصبی مصنوعی² ابداع شده‌اند که با اقتباس از فرآیند یادگیری مغز انسان می‌توانند روابط بین متغیرها را، هر چند پیچیده و غیرخطی، کشف کنند (ژانگ و هو، 1998). اخیراً با رشد الگوریتم‌های ابتکاری و هوش مصنوعی از جمله، شبکه‌های عصبی و منطق فازی و کاربردهای آن به عنوان ابزاری قدرتمند به منظور تجزیه و تحلیل داده‌ها، توجه اقتصاددانان نیز به این روش‌های پیش‌بینی جلب شده است و به این دلیل مدل‌های مختلفی جهت پیش‌بینی متغیرهای اقتصادی پیشنهاد شده است. برخی از قابلیت‌های روش‌های یاد شده از جمله ظرفیت استفاده از روابط پیچیده و غیرخطی انگیزه بکارگیری این روش‌ها در مسائل اقتصادی و مالی به ویژه پیش‌بینی قیمت را تقویت نموده است. البته مطالعاتی هم وجود دارد که بیانگر برتری مدل‌های خطی بر مدل‌های شبکه عصبی و سایر روش‌های غیرخطی است. برای مثال، پرچگال³ (1995) در مطالعه‌ای به پیش‌بینی تولید ناخالص بخش صنعت برزیل با استفاده از سه روش شبکه عصبی، مدل اجزای غیر قابل مشاهده⁴ و فرایند ARIMA پرداخت که نتایج حاکی از برتری پیش‌بینی حاصل از روش ARIMA است. همچنین چرچ و کورام⁵ (1996) مخارج مصرفی مصرف‌کنندگان انگلیسی را با استفاده از مدل‌های اقتصادسنجی و شبکه‌های عصبی پیش‌بینی و مقایسه نموده‌اند که نتایج مطالعه حاکی از آن است که پیش‌بینی حاصل از شبکه‌های عصبی بهتر از روش‌های اقتصادسنجی نبوده است. البته این شواهد بدان معنی نیست که همواره روش‌های خطی بر روش‌های غیرخطی برتری داشته‌اند. مطالعات تجربی فراوانی نیز نشان دهنده ارجحیت روش‌های غیرخطی بر الگوهای خطی است. بنابراین، برای انتخاب مدل بهینه، بررسی ماهیت متغیرها با استفاده از آزمون‌های مرسوم مانند آزمون پراک-دیکرت شاینکمن، بُعد همبستگی⁶، نمای لیاپانوف و... کمک شایانی به محقق خواهد نمود. بنابراین در این پژوهش ابتدا ساختار مولد قیمت روزانه طلا بررسی و سپس با استفاده از سه روش ARMA،

¹ Zhang and Hu

² Artificial Neural Network

³ Portugal

⁴ Unobserved Component Models

⁵ Church and Curram

⁶ Dimension Correlation

GARCH^۱ و ANFIS^۲ به پیش‌بینی روند آتی آن پرداخته شده است، و در نهایت نتایج مدل‌های خطی و غیرخطی با هم مقایسه شده است.

2- مروری بر مطالعات پیشین

در این بخش به برخی مطالعات تجربی در زمینه پیش‌بینی متغیرهای مالی اشاره شده است. وجه مشترک این مطالعات برتری روش‌های غیرخطی بر روش‌های خطی است. تالی و لوسی^۳ (2007) به پیش‌بینی قیمت نقدی و آتی طلا در بورس پرداخته‌اند. در این تحقیق داده‌های مربوط به طلا و دیگر متغیرهای اقتصادی از سال 1984 تا 2003 جمع آوری شده است. آنها از متغیرهای مستقل متعددی استفاده کرده‌اند و از انواع روش‌های خودرگرسیون واریانس ناهمسان شرطی از جمله، روش تعمیم‌یافته، روش سطح آستانه^۴، تیلور و نمایی^۵ و روش اهرمی استفاده کردند که در نهایت روش نامتقارن خود رگرسیون ناهمسان شرطی تعمیم یافته به عنوان روش برتر انتخاب شده است. دونیس و ناتانی^۶ (2007) تحقیقی با عنوان داد و ستد کمی^۷ (مقداری) طلا و نقره با استفاده از روش‌های غیرخطی انجام داده‌اند. آنها در این تحقیق از روش خطی خود رگرسیون میانگین متحرک و روش‌های غیرخطی مانند نزدیک‌ترین همسایه^۸، پرسپترون چندلایه و شبکه عصبی رتبه‌ای استفاده کرده‌اند و با معیارهای آماری نظیر تشخیص صحیح تغییرات^۹ و معیارهای مالی مانند بازده تعدیل شده ریسک^{۱۰} مدل‌ها را مورد ارزیابی قرار دادند. نتایج تحقیق بیانگر برتری مدل‌های غیرخطی نسبت به مدل‌های خطی است. پاریزی و دیگران^{۱۱} (2008) برای پیش‌بینی یک تا شش گام به جلو تغییرات قیمت طلا از شبکه‌های عصبی چرخشی^{۱۲} و شبکه عصبی بازگشتی استفاده کرده‌اند. نتایج آنها نشان داد که شبکه‌های عصبی نسبت به مدل خود رگرسیون میانگین متحرک برتری دارد.

¹ Generalized Auto Regressive Conditional Heteroskedasticity

² Adaptive Neuro Fuzzy Inference System

³ Tully and lucey

⁴ Threshold

⁵ Exponential

⁶ Dunis and Nattani

⁷ Quantitative

⁸ Nearest Neighbors

⁹ Correct Directional Change

¹⁰ Risk Adjusted Return

¹¹ Parisi and Diaz

¹² Rolling Neural Network

فهمی فرد¹ و دیگران (2009) به مقایسه شبکه عصبی فازی و ARIMA در پیش‌بینی نرخ نرخ ارز به صورت روزانه پرداختند و نشان دادند پیش‌بینی به روش غیر خطی شبکه عصبی فازی نسبت به روش خطی ARIMA ترجیح داده می‌شود.

یایار² و دیگران (2011) در مطالعه‌ای به مقایسه پیش‌بینی مصرف انرژی الکتریکی با استفاده از روش‌های ARIMA و شبکه عصبی فازی پرداخته‌اند. نتایج تحقیق نشان داد که شبکه عصبی فازی پیش‌بینی دقیق‌تری نسبت به مدل ARIMA ارائه می‌دهد.

همچنین از جمله مطالعات داخلی می‌توان به پژوهش قدیمی و مشیری (1381) اشاره کرد. آن‌ها کارایی مدل شبکه عصبی در مقایسه با مدل رگرسیون خطی را در پیش‌بینی نرخ رشد اقتصادی ایران مقایسه نموده‌اند. بدین منظور، ابتدا یک مدل رگرسیون رشد برای دوره 1315-1373 برآورد شده و سپس با همان مجموعه رگرسورها (متغیرهای ورودی) یک مدل شبکه عصبی طراحی و تخمین زده شده است. پس از آن، با استفاده از معیارهای مرسوم ارزیابی مدل‌های رقیب، کارایی دو مدل فوق در زمینه پیش‌بینی نرخ رشد اقتصادی در ایران در دوره 1374-1380 مقایسه شده است. نتایج نشان می‌دهد که مدل شبکه عصبی برای پیش‌بینی نرخ رشد اقتصادی در ایران از کارایی بالاتری برخوردار است.

حمید (1387) در پایان‌نامه خود اقدام به پیش‌بینی تورم ماهانه، فصلی و سالانه ایران با استفاده از مدل‌های ساختاری و سری زمانی کرده است. در این پژوهش از داده‌های دوره زمانی 85-1338 استفاده شده است. نتایج این پژوهش نشان می‌دهد که بهترین شبکه، شبکه‌هایی هستند که با الگوریتم لونیبرگ مارکوارت³، آموزش داده شوند و توابع انتقال لایه-لایه‌های میانی غیرخطی و توابع انتقال لایه خروجی آن‌ها خطی باشد.

زراءنژاد و دیگران (1391) از یک شبکه عصبی فازی ANFIS بر مبنای مدل تاکاگی-سوگنو⁴ و همچنین الگوریتم یادگیری ترکیبی پس انتشار و حداقل مربعات خطا در جهت بهبود دقت پیش‌بینی و افزایش سرعت همگرایی استفاده کرده‌اند. بازه زمانی به کار گرفته شده برای پیش‌بینی قیمت روزانه طلا در مطالعه مذکور از 2010/7/12 تا 2012/5/18 است. نتایج با توجه به معیارهای متداول ارزیابی خطای پیش‌بینی نشان می‌دهد که مدل شبکه عصبی فازی ANFIS نسبت به مدل ARIMA پیش‌بینی دقیق‌تری ارائه داده است.

¹ Fahimifard

² Yayar

³ Levenberg-Marquardt Algorithm

⁴ Takagi Sugeno

3- روش‌شناسی تحقیق

3-1- مدل ARMA

به طور کلی فرآیندی را $ARMA(p, q)$ می‌نامند که شامل p مرتبه جمله خود رگرسیون و q مرتبه جمله میانگین متحرک باشد. به عبارت دیگر، شامل p مرتبه جمله با وقفه از متغیر وابسته و q مرتبه جمله با وقفه از جملات اخلال باشد. همچنین اگر یک سری پس از d مرتبه تفاضل‌گیری مانا شود و سپس آن را توسط فرآیند $ARMA(p, q)$ مدل‌سازی کنیم، در این صورت سری زمانی اصلی، سری زمانی خود رگرسیونی میانگین متحرک انباشته $ARIMA(p, d, q)$ می‌باشد (گجراتی، 2008). مدل عمومی $ARMA(p, q)$ عبارت است از:

$$y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \dots - \theta_q \varepsilon_{t-q}$$

$$\varepsilon_t \sim i.i.d(0, \sigma^2)$$

که در آن ε_t سری نوفه سفید و p و q اعداد صحیح غیرمنفی هستند؛ ضمن این که ϕ_p و θ_q ضرایب مدل هستند.

3-2- مدل GARCH

زمانی نسبتاً طولانی است که اقتصادسنجی‌دانان و محققان پی‌برده‌اند که بازده دارایی‌های مالی دارای ویژگی خوشه‌بندی تغییرات¹ است؛ یعنی توزیع احتمال فراوانی آن‌ها چولگی و کشیدگی بیشتری از توزیع احتمال فراوانی نرمال دارد. در دو دهه اخیر مدل‌های آماری که بتوانند این وابستگی‌ها را نشان دهند به وجود آمده‌اند. اولین مدل برای توضیح وابستگی از نوع خوشه‌بندی تغییرات سری زمانی توسط انگل² (1982) مطرح شد. وی مدل خودرگرسیون واریانس ناهمسان شرطی (ARCH) را برای توجیه این نوع از وابستگی‌ها در سری زمانی مطرح نمود. بعد از وی مطالعات گوناگونی توسط سایر اقتصاددانان مانند بولرسلو³ (1986) صورت گرفت و مدل‌های دیگری از نوع ARCH مانند مدل خودرگرسیون واریانس ناهمسان شرطی تعمیم‌یافته (GARCH) به وجود آمدند تا بتوانند این ویژگی بازدهی‌های دارایی‌های مالی را به خوبی توضیح دهند.

¹Volatility Clustering

²Engel

³Bollerslev

انواع مختلف از مدل‌های ARCH در پیش‌بینی اقتصادی استفاده می‌شود که معروف‌ترین آنها عبارتند از: مدل ARCH(p)، مدل GARCH(p, q)، ARCH-M، EGARCH^۱ و مدل IGARCH^۲. از هر یک از این مدل‌ها با توجه به نوع و مشخصه داده‌های به کار گرفته شده در پیش‌بینی استفاده می‌شود، اما بیشتر مطالعات تجربی نشان داده‌اند که مدل‌های نوع GARCH از توانایی بیشتر در مدل‌سازی و پیش‌بینی برخوردار می‌باشد. یک مدل کلی ARCH(q) به صورت زیر است (بلسلو، 1986):

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + V_t \quad (2)$$

مشکلی که در عمل به هنگام استفاده از این مدل‌ها به وجود می‌آید، این است که وقتی q عدد بزرگی باشد، به طور معمول باعث نقض شدن فرض غیرمنفی بودن و شرایط مانایی معادله واریانس می‌شود. مدل GARCH که توسط بلسلو (1986) توسعه یافت، راه‌کاری برای حل این مشکل و نیز مدلی صرفه‌جو در تعداد پارامترها می‌باشد (جانستون و اسکات^۴، 2000). به دلیل تعداد پارامترهای زیادی که برای یک مدل ARCH باید تخمین زده می‌شد، بلسلو (1986) این مدل را به صورت تعمیم‌یافته ارائه داد که در این مدل تعمیم‌یافته، معادله واریانس شرطی علاوه بر q توان دوم خطای گذشته، شامل p وقفه واریانس‌های شرطی گذشته (σ_{t-j}^2) نیز است. معادله واریانس شرطی در یک مدل GARCH(p, q) به صورت زیر می‌باشد (باچاد و ماتاز^۵، 2001):

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 + V_t \quad (3)$$

3-3- مدل شبکه عصبی فازی ANFIS

طی سالیان اخیر روش‌های جدیدی از پیش‌بینی به نام محاسبات نرم^۶ ابداع شده است که می‌توانند روابط بین متغیرها را، هر چند پیچیده و غیرخطی، کشف کنند. امروزه، روش‌های محاسبات نرم از جمله شبکه‌های عصبی و عصبی فازی به عنوان رقیب قدرتمند مدل‌های غیرخطی برای پیش‌بینی، مدل‌سازی و شبیه‌سازی سری‌های زمانی مورد استفاده قرار

¹ ARCH in Mean Model

² Exponential GARCH

³ Integrated GARCH

⁴ Johnston and Scott

⁵ Bouchad and Matacz

⁶ Soft Computing

گرفته‌اند. تا مدت‌ها روش‌های آماری چون رگرسیون خطی یا چند جمله‌ای، مدل‌های ساختاری، مدل‌های سری زمانی مانند اتورگرسیو میانگین متحرک (ARIMA)، هموارسازی نمایی¹ و مواردی از این قبیل به عنوان تنها ابزارهای پیش‌بینی مورد استفاده قرار می‌گرفتند. اما این مدل‌ها ضعف‌هایی دارند که به محقق اجازه نمی‌دهند عوامل پیچیده و غیر خطی موثر بر پیش‌بینی را در نظر بگیرد. حتی مدل‌های غیر خطی رایج نظیر مدل‌های ARCH، GARCH، TAR و ... نیز که تاکنون مورد استفاده قرار می‌گرفتند، اغلب برای یک مساله خاص، مفید واقع می‌شوند، در حالی که در حل مسائل دیگر ممکن است ناموفق ظاهر شوند. از سوی دیگر، یک مدل غیر خطی خاص ممکن است به تنهایی قادر به حذف تمام الگوهای غیر خطی از داده‌ها نباشد. بر خلاف روش‌های غیر خطی متداول، شبکه‌های عصبی قادر به حذف تمام ساختارهای غیر خطی داده‌ها هستند (ژانگ و هو، 2001).

برای پیش‌بینی، شبکه، فضای ورودی (مقادیر جاری و گذشته‌ی سری زمانی و سایر متغیرهای توضیحی) را به فضای خروجی (مقادیر پیش‌بینی) می‌نگارد. برای ایجاد الگوهای ورودی² از سری زمانی اصلی، پنجره‌ای با طول ثابت از روی سری زمانی عبور داده می‌شود (ژانگ و هو، 2001). خروجی یک شبکه عصبی که برای پیش‌بینی یک سری زمانی از آن استفاده می‌شود را می‌توان به صورت زیر نشان داد:

$$\hat{P}_t = f(P_{t-1}, P_{t-2}, \dots, P_{t-i}) \quad (4)$$


\hat{P}_t مقدار پیش‌بینی متغیر در زمان t و i بعد بردار ورودی یا تعداد وقفه‌هایی است که در مدل وارد شده و f تابعی غیرخطی است. می‌توان رابطه فوق را به صورت زیر نشان داد:

$$\hat{P}_t = b_0 + \sum_{i=1}^q w_i \tanh \left(b_{i0} + \sum_{j>1} w_{ij} p_{t-1} \right) \quad (5)$$

در این رابطه b_0 عدد ثابت (برابر با یک) در لایه‌ی میانی، b_{i0} عدد ثابت لایه ورودی، w_i وزن‌های ارتباطی بین لایه‌ی میانی و لایه خروجی و w_{ij} وزن‌های ارتباطی لایه‌ی ورودی و لایه میانی‌اند. \tanh نیز نشان دهنده تانژانت تابع هایپربولیک است. یک شبکه عصبی فازی با دو لایه ورودی در نمودار 1 مشاهده می‌شود.

¹ Exponential Smoothing

² Input Pattern



نمودار (1): ساختار شبکه عصبی فازی با دو لایه ورودی

منبع: ژانگ و هو (2001)

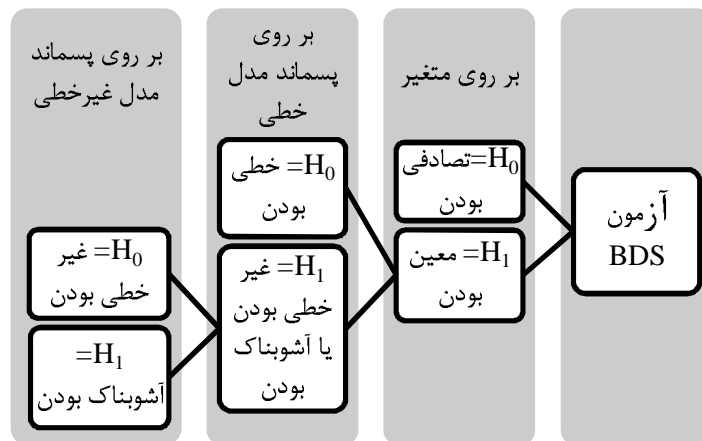
3-4- آزمون براک-دیگرت-شاینکمن (BDS)

براک، دیگرت و شاینکمن¹ در سال 1987 آزمون آماری که بر مبنای فرض استقلال و توزیع یکسان (IID) اعضای سری زمانی است، ارائه دادند. آزمون BDS تصادفی بودن پسماندهای یک مدل خطی یا غیرخطی را می‌آزماید. در این بخش از این آزمون به منظور بررسی وضعیت ساختار فرآیند ایجاد کننده داده‌ها به لحاظ خطی یا غیر خطی بودن استفاده می‌شود. آماره DBS به صورت زیر تعریف می‌شود:

$$W_{m,T}(\varepsilon) = \sqrt{T} [C_{m,T}(\varepsilon) - C_{1,T}(\varepsilon)^m] / \sigma_{m,T}(\varepsilon) \quad (6)$$

که در آن: $\sigma_{m,T}$ انحراف استاندارد عبارت داخل براکت در فرمول فوق، m بُعد و ε مقدار دلخواه و کوچک است. آماره $W_{m,T}(\varepsilon)$ در نمونه‌های به حد کافی بزرگ دارای توزیع نرمال با میانگین صفر و واریانس ثابت است؛ بنابراین، مقدار بزرگ W منجر به رد فرضیه صفر و دلیلی بر وجود وابستگی (از نوع خطی و یا غیر خطی) در سیستم خواهد بود و مقدار نزدیک به صفر آن به معنی پذیرش فرض صفر و تاییدی بر استقلال و توزیع یکسان مشاهدات است. در این آماره، انتخاب مقدار ε بسیار مهم است و اغلب به صورت ضربی از انحراف استاندارد سری زمانی انتخاب می‌شود. مطابق با نمودار 2 برای بررسی خطی یا غیر خطی بودن داده‌های بازدهی روزانه قیمت طلا، در سه مرحله از آزمون BDS استفاده شده است. ابتدا آزمون بر روی بازدهی روزانه قیمت طلا، سپس بر پسماندهای مدل ARMA و در مرحله سوم بر پسماندهای مدل‌های GARCH انجام می‌گیرد.

¹ Scheinkman, Dechert & Brock



نمودار (2): مراحل مختلف انجام آزمون BDS

منبع: زئوفی (1392)

بر اساس نمودار ۲ اگر آزمون BDS برای داده‌های خام صورت گیرد، فرضیه آزمون به صورت زیر خواهد بود:

H_0 : تصادفی بودن فرآیند سری زمانی

H_1 : معین و غیر تصادفی بودن فرآیند سری زمانی

چون آماره آزمون BDS دارای توزیع Z می‌باشد برای تصمیم‌گیری در مورد این آزمون از مقدار بحرانی آماره Z در سطح معنی داری 5% یعنی 2/64 و سطح معنی داری 10% یعنی 1/64 و مقایسه آن با آماره محاسباتی استفاده می‌شود.

همچنین در صورت انجام آزمون بر روی پسماند مدل‌های خطی (در اینجا مدل ARMA) فرضیه آزمون به صورت زیر است:

H_0 : فرآیند خطی سری زمانی

H_1 : مدل غیر خطی است و نه الزاماً آشوبی


در مرحله آخر برای شناسایی ساختار آشوبی، ساختار غیرخطی مدل با استفاده از مدل‌های GARCH، استخراج می‌شود و آزمون BDS روی پسماندهای این مدل انجام می‌شود. فرضیه صفر در این آزمون به صورت زیر است:

H_0 : فرآیند غیر خطی در مدل

H_1 : فرآیند آشوبی در مدل


4- ویژگی‌های آماری سری زمانی بازدهی قیمت طلا

داده‌های مورد استفاده در این پژوهش، بازده روزانه قیمت جهانی طلا از تاریخ 2011/07/25 تا 2012/12/17 است که از سایت شورای جهانی طلا¹ دریافت شده و در مجموع 366 مشاهده را در بر می‌گیرد. سری مورد نظر به دو گروه آموزش² (داده‌های درون نمونه شامل 295 داده) و گروه آزمون³ (داده‌های خارج از نمونه⁴ شامل 71 داده) تقسیم شده است. از داده‌های آموزش برای آموزش و مدل‌سازی و از داده‌های آزمون برای پیش‌بینی خارج از نمونه و مقایسه مدل‌های مختلف استفاده می‌نماییم. نمودار شماره 3 و 4 به ترتیب روند روزانه قیمت طلا و روند روزانه بازده قیمت طلا را در این دوره نشان می‌دهد.



نمودار (3): روند روزانه قیمت طلا

منبع: یافته‌های تحقیق



نمودار (4): روند روزانه بازده قیمت طلا

منبع: یافته‌های تحقیق

¹ World Gold Council: www.gold.org

² Training Set

³ Test Set

⁴ Out of sample

جدول 1 ویژگی‌های آماری بازده روزانه قیمت طلا را در دوره مورد بررسی نشان می‌دهد. همان طور که برای سری زمانی بازده انتظار می‌رود، میانگین مثبت است. شواهد نشان از چولگی¹ منفی در توزیع بازده روزانه قیمت طلا دارد که به معنی احتمال زیاد برای کاهش‌های بزرگ نسبت به افزایش‌ها می‌باشد. این آماره نشان می‌دهد که بازده قیمت طلا نامتقارن است. همچنین سری بازده روزانه قیمت طلا، دارای کشیدگی² پایین می‌باشد. آماره جارکو-برا نشان می‌دهد که با احتمال بسیار بالا فرض صفر مبنی بر نرمال بودن توزیع بازده قیمت طلا رد می‌شود، لذا سری بازدهی قیمت طلا از توزیع نرمال تبعیت نمی‌کند.

جدول (1): ویژگی‌های آماری بازدهی قیمت طلا

متغیر	بازدهی طلا
تعداد مشاهدات	366
کشیدگی	5/931
چولگی	-0/4765
انحراف معیار	1/2976
حداقل	-5/816
حداکثر	4/561
میانه	0/02867
میانگین	0/01553
جارکو-برا	144/892
احتمال جارکو-برا	0

منبع: یافته‌های تحقیق

5- یافته‌های تحقیق

در این بخش ابتدا مدل خطی ARMA و مدل غیرخطی GARCH برآورد، و بر اساس آن اقدام به پیش‌بینی متغیر بازده روزانه قیمت طلا شده است. سپس برای بررسی آشوبناک بودن ساختار داده‌ها، با استفاده از پسماند مدل‌های ARMA و GARCH، آزمون BDS انجام شده است. در نهایت از مدل ANFIS به عنوان مدلی غیرخطی که توانایی مدل‌سازی ساختار آشوبناک داده‌ها را داراست برای پیش‌بینی استفاده شده است.

¹ Skewness

² Kurtosis

5-1- مدل ARMA

برای پیش‌بینی با مدل $ARIMA(p, d, q)$ از متدولوژی باکس - جنکینز استفاده می‌شود که دارای چهار مرحله شناسایی؛ برآورد، آزمون‌های کنترل تشخیصی و پیش‌بینی است (گرنجر و نیولبد¹، 1986).

اولین مرحله در این متدولوژی بررسی مانایی سری زمانی است. بدین منظور از آزمون دیکی فولر تعمیم یافته² استفاده شده است. نتایج این آزمون در جدول 2 حاکی از این است که سری مورد استفاده در سطح ماناست که در جدول زیر نمایش داده شده است.

جدول (2): آزمون دیکی فولر برای بررسی مانایی متغیر بازدهی طلا

نام متغیر	آماره t برای آزمون دیکی فولر تعمیم یافته
بازدهی قیمت روزانه طلا	-19/50 (0/000)

منبع: یافته‌های تحقیق (اعداد داخل پرانتز مقادیر احتمال می‌باشد)

برای انتخاب وقفه بهینه، مدل ARMA با وقفه‌های مختلف AR و MA در جدول 3 آورده شده است. همانطور که در این جدول ملاحظه می‌شود با استفاده از معیار آکائیک، 10 وقفه بهینه برای اتورگرسیو (AR) و 9 وقفه برای میانگین متحرک در نظر گرفته شده است. در ادامه با استفاده از مدل بهینه $ARMA(10, 9)$ اقدام به مدل‌سازی و پیش‌بینی شده است که در نمودار شماره 5 مقادیر واقعی خط پیرنگ با نوسانات زیاد و مقادیر برازش شده از طریق پیش‌بینی خط کم رنگ با نوسانات کم است. چنانچه از نمودار 3 پیداست پیش‌بینی خطی ARMA نتوانسته است به خوبی نوسانات بازده را پیش‌بینی کند و مقدار خطای پیش‌بینی که در نمودار زیرین نشان داده شده است، قابل توجه می‌باشد.

¹ Granger and Newbold

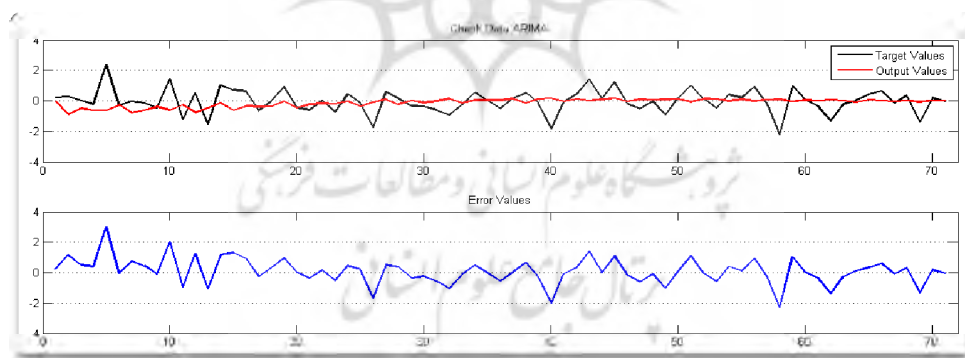
² Augmented DickeyFuller test

جدول (3): تعیین وقفه بهینه برای مدل ARIMA با استفاده از معیار آکائیک

10	9	8	7	6	5	4	3	2	1	0	
3.386	3.393	3.398	3.399	3.396	3.396	3.392	3.386	3.382	3.38	3.375	0
3.386	3.38	3.399	3.396	3.39	3.388	3.384	3.391	3.38	3.384	3.38	1
3.388	3.387	3.362	3.386	3.382	3.379	3.312	3.306	3.298	3.387	3.382	2
3.356	3.352	3.358	0	3.387	3.319	3.314	3.357	3.305	3.391	3.387	3
3.361	3.368	3.369	3.315	3.313	3.31	3.306	3.369	3.311	3.385	3.392	4
3.315	3.327	3.379	3.277	3.272	3.267	3.31	3.319	3.392	3.387	3.396	5
3.309	3.304	3.269	3.282	3.275	3.272	3.313	3.387	3.381	3.392	3.397	6
3.278	3.304	3.242	3.239	3.258	3.276	3.314	3.389	3.387	3.398	3.402	7
3.282	3.31	3.264	3.242	3.382	3.282	3.368	3.367	3.367	3.4	3.403	8
3.274	3.264	3.31	3.304	3.307	3.284	3.327	3.358	3.334	3.388	3.398	9
3.247	3.196	3.213	3.31	3.279	3.368	3.363	3.363	3.385	3.401	3.398	10

توضیحات: سطرها نشان دهنده AR و ستون‌ها نشان دهنده MA است

منبع: یافته‌های تحقیق

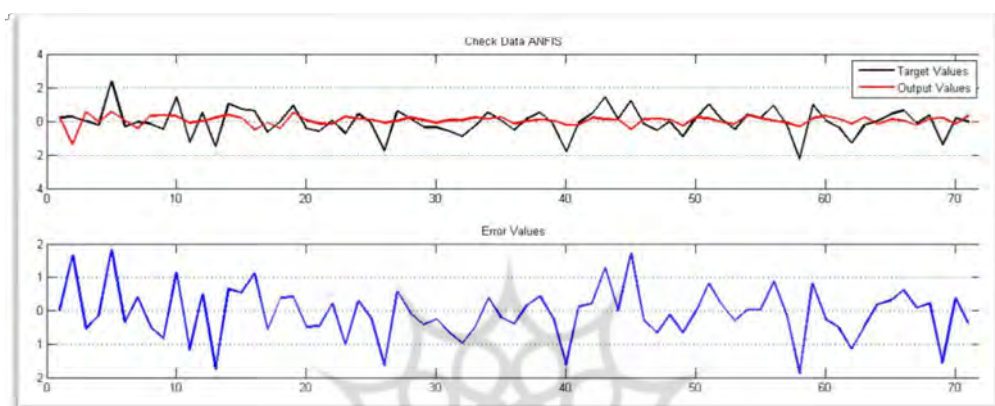


نمودار (5): پیش‌بینی بازدهی روزانه قیمت طلا به روش ARMA

منبع: یافته‌های تحقیق

5-2- مدل GARCH

به منظور جداسازی اثرات غیرخطی از سری روزانه قیمت طلا و همچنین پیش‌بینی با مدل GARCH، ابتدا مدل $GARCH(1, 1)$ بر داده‌ها برازش شده و سپس با استفاده از نتایج به دست آمده پیش‌بینی‌ها انجام گرفته است. نتایج پیش‌بینی خارج از نمونه مدل $GARCH(1, 1)$ در نمودار 6 نشان داده شده است.



نمودار (6): پیش‌بینی بازدهی روزانه قیمت طلا به روش GARCH

منبع: یافته‌های تحقیق

با توجه به شکل و مقدار خطای پیش‌بینی، مدل GARCH نیز توفیق چندانی در مدل‌سازی متغیر بازده طلا نداشته و نتوانسته ساختار غیرخطی داده‌ها را به خوبی شناسایی کند. با نتایج بدست آمده به نظر می‌رسد مدل‌سازی چنین داده‌ای نیازمند مدل‌های پیچیده‌تری مانند محاسبات نرم باشد.

5-3- نتایج آزمون براک-دیگرت-شاینکمن (BDS)

با توجه به نتایج ضعیف بدست آمده از روش‌های ARMA و GARCH، در این بخش به بررسی وجود فرایند آشوبی در سری مورد نظر پرداخته شده است. بدین منظور از آزمون BDS برای شناسایی رفتار غیرخطی و آشوبناک داده‌ها استفاده شده است. نتایج این آزمون در جدول 4 قابل مشاهده است.

با توجه به نتایج آزمون BDS بر روی متغیر بازده طلا (داده‌های خام)، فرضیه صفر مبنی بر تصادفی بودن سری زمانی رد و فرضیه مقابل آن که بیان‌کننده معین بودن سری است پذیرفته می‌شود. لازم به ذکر است که معین بودن سری الزاماً به معنای آشوبی بودن آن

نیست. همچنین با توجه به نتایج آزمون BDS بر روی پسماند مدل خطی ARMA در جدول 4 مشاهده می‌شود که در تمامی ابعاد و همچنین مقادیر مختلف ε فرضیه صفر مبنی بر خطی بودن سری مورد مطالعه رد و فرضیه مقابل مبنی بر وجود رفتار غیرخطی در متغیر در سطح 5 درصد و 10 درصد پذیرفته می‌شود.

در نهایت با انجام آزمون BDS بر روی پسماندهای مدل غیرخطی GARCH وجود فرایند آشوبی در ساختار متغیر، بررسی می‌شود. با توجه به نتایج جدول 4 مشاهده می‌شود که مقدار آماره آزمون از مقادیر بحرانی بیشتر است و فرضیه صفر رد می‌شود و می‌توان وجود فرایند آشوبی در ساختار داده‌های مورد بررسی را پذیرفت.

جدول (4): نتایج آزمون BDS

M=6	M=5	M=4	M=3	M=2		ε
4.04	3.54	3.42	3.17	3.10	متغیر	0.5
3.27	2.17	-2.12	-2.62	-2.04	ARIMA	
-3.52	-3.53	-2.83	-2.56	2.16	GARCH	
3.54	3.17	3.01	2.92	2.76	متغیر	1
-2.67	-2.44	-2.56	-2.55	-2.23	ARIMA	
-2.04	-2.23	-2.21	-2.20	2.22	GARCH	
4.74	4.56	4.38	4.12	3.27	متغیر	2
-2.31	2.16	-2.07	-2.56	-3.25	ARIMA	
3.31	3.00	2.93	2.49	2.16	GARCH	

منبع: یافته‌های تحقیق

با توجه به اینکه وجود فرایند آشوبی در سری مورد مطالعه تایید می‌شود، در ادامه با طراحی یک مدل شبکه عصبی فازی ANFIS، که مزیت آن نسبت به روش‌های پیشین ذکر شد، به پیش‌بینی بازده قیمت طلا می‌پردازیم و نتیجه آن را با سایر مدل‌ها مقایسه می‌کنیم.

5-4- مدل شبکه عصبی فازی ANFIS

برای آموزش و پیش‌بینی شبکه عصبی فازی از کد نویسی در نرم افزار متلب¹ نسخه 2010 استفاده شده است. مدل مورد استفاده یک سامانه استنتاج فازی سوگنو² با تابع عضویت ورودی «تفاوت دو تابع سیگموئید» و توابع خروجی خطی است که در یک ساختار عصبی اجرا و برای فرآیند آموزش از ترکیبی از روش‌های آموزش پس‌انتشار خطا و حداقل مربعات خطا استفاده می‌شود. بدین صورت یک سیستم عصبی فازی طراحی شده که بدین صورت عمل می‌کند؛ در هر دور آموزش، هنگام حرکت رو به جلو خروجی‌های گره‌ها به صورت عادی تا لایه آخر محاسبه می‌شوند و سپس پارامترهای نتیجه توسط روش کم‌ترین مجموع مربعات خطا محاسبه می‌شوند. در ادامه پس از محاسبه خطا در بازگشت رو به عقب نسبت خطا بر روی پارامترهای شرط، پخش شده و با استفاده از روش شیب نزولی خطا مقدار آن‌ها تصحیح می‌شود.

در این مطالعه 80 درصد داده‌ها برای آموزش و 20 درصد باقی مانده برای پیش‌بینی در نظر گرفته شده است. برای مدل‌سازی و آموزش شبکه از طریق تغییر مداوم توابع عضویت مختلف، تعداد توابع عضویت و تعداد وقفه‌های متغیر، از طریق آزمون و خطا، شبکه‌ای با سه تابع عضویت «تفاوت دو تابع سیگموئید» برای ورودی و توابع خطی برای خروجی و نه وقفه از متغیر ساخته شد و برای غیر فازی کردن از روش میانگین موزون استفاده شد. نمودار 7 نشان دهنده بهبود خطای داده‌های آموزش است.



نمودار (7): خطای آموزش توسط ANFIS

منبع: یافته‌های تحقیق

¹ Matlab

² Sugeno fuzzy inference

6- مقایسه کارایی 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. هایکین¹ (1994)، برای بررسی کارایی مدل‌های پیش‌بینی سری‌های زمانی، معیارهای متنوعی را معرفی کرد که ما در این تحقیق از ریشه میانگین مجذور خطا (RMSE)²، میانگین قدر مطلق خطا (MAE)³، درصد میانگین مطلق خطاهای پیش‌بینی (MAPE)⁴ و ضریب نابرابری تایل (TIC)⁵ استفاده کرده‌ایم. فرمول این معیارها به صورت زیر است:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (7) \quad MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| * 100 \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (9) \quad TIC = \frac{\sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}}{\sqrt{\sum_{i=1}^n \hat{Y}_i/n + \sqrt{\sum_{i=1}^n Y_i/n}}} \quad (10)$$

بسیاری از مطالعات اقتصادسنجی در زمینه پیش‌بینی، صحت پیش‌بینی مدل‌ها را با استفاده از آماره‌های فوق مورد بررسی قرار داده‌اند. با این حال در مواردی که معیارهای مذکور صحت پیش‌بینی را تایید نموده باشند الزاماً مدل، پیش‌بینی صحیحی انجام نداده است (بروکز⁶، 2008). گرلو، ایروین و لیو⁷ (1993) نشان داده‌اند که، صحت پیش‌بینی بر اساس معیارهای آمار سنتی (مانند معیارهای فوق)، رهنمود اندکی در مورد مفید بودن به کارگیری آن پیش‌بینی‌ها در مبادلات بازار سرمایه ارائه می‌کنند. بنابراین، اگر مدلی که در زمینه آماری ضعیف عمل می‌کنند در زمینه بازار سهام به کار برده شوند ممکن است مفید یا مضر باشند. در بازار سرمایه، مدلی که می‌توانند به درستی علامت بازدهی‌های آتی را پیش‌بینی کنند یا می‌توانند نقاط برگشت (تغییر جهت قیمت) یک سری را

¹ Hykin

² Root Mean Squared Error (RMSE).

³ Mean Absolute Error (MAE).

⁴ Mean Absolute Percentage Error (MAPE).

⁵ Theil inequality coefficient (TIC)

⁶ Brooks

⁷ Gerlow, Irowin and Liu

پیش‌بینی کنند، مفیدتر خواهند بود (لیچ و تانر^۱، ۱۹۹۱). دو معیار برای توانایی یک مدل پیش‌بینی تغییر علامت‌ها (بدون توجه به مقادیر متغیرها) توسط پسران و تیمرمن^۲ (۱۹۹۲) و رفنز (۱۹۹۵) ارائه شده‌اند. فرمول‌های مربوطه برای محاسبه معیارهای مذکور به شرح زیر می‌باشند:

اولین شاخص، درصد صحت پیش‌بینی علامت‌ها^۳ است که با استفاده از رابطه‌ی زیر محاسبه محاسبه می‌شود:

$$CSP = \frac{1}{T - (T_1 - 1)} \sum_{t=T_1}^T Z_{t+s} \quad (11)$$

که:

$$\begin{aligned} Z_{t+s} &= 1 && \text{If } (y_{t+s} * f_{t,s}) > 0 \\ Z_{t+s} &= 0 && \text{Otherwise} \end{aligned} \quad (12)$$

که در آن:

T: اندازه کل نمونه (داده‌های نمونه و خارج از نمونه)

T₁: اولین مشاهده خارج از نمونه

f_{t,s}: پیش‌بینی s گام جلوتر متغیر در زمان t

Y_t: مقدار واقعی متغیر در زمان t

شاخص دوم، شاخص درصد صحت پیش‌بینی تغییر علامت‌ها^۴ است که از طریق فرمول زیر محاسبه می‌شود:

$$CDCP = \frac{1}{T - (T_1 - 1)} \sum_{t=T_1}^T Z_{t+s} \quad (13)$$

که:

$$\begin{aligned} Z_{t+s} &= 1 && \text{If } (y_{t+s} - y_t)(f_{t,s} - y_t) > 0 \\ Z_{t+s} &= 0 && \text{Otherwise} \end{aligned} \quad (14)$$

همچنین برای اینکه از نظر آماری نیز فرضیه برابری صحت پیش‌بینی‌ها در مدل‌های رقیب مورد آزمون قرار گیرند از آزمون مرگان-گرنجر-نیوبلد (MGN) استفاده شد (دیبولد و

¹ Leitch and Tanner

² Pesaran and Timmerman

³ Correct Sign Predictions

⁴ Correct Direction Change Predictions

ماریانو¹، 2002). به عبارتی هر چند معیارهای ارزیابی اشاره شده در بالا از جمله معیارهای کاربردی و مفید در زمینه بررسی قدرت پیش‌بینی روش‌های مختلف هستند، هیچ کدام از آن‌ها قادر نیستند برتری یک روش را به صورت آماری بررسی کنند. طبق این فرمول، ابتدا خطای پیش‌بینی دو روش مختلف که با $e_{1,t}$ و $e_{2,t}$ نشان داده می‌شود محاسبه می‌گردد. سپس مجموع (S_t) و تفاوت (D_t) خطای پیش‌بینی بر اساس روابط زیر محاسبه می‌گردد.

$$\begin{aligned} S_t &= e_{1,t} + e_{2,t} \\ D_t &= e_{1,t} - e_{2,t} \\ e_{1,t} &= x_m - x_{1p} \\ e_{2,t} &= x_m - x_{2p} \end{aligned} \quad (15)$$

که در آن x_{1p} و x_{2p} به ترتیب مقادیر پیش‌بینی شده خروجی توسط مدل اول و دوم (مدل‌های رقیب) و x_m مقادیر اندازه‌گیری شده خروجی می‌باشند. آزمون برابری میانگین مربعات خطای دو روش مختلف، در مقابل کمتر بودن خطای مدل اول را می‌توان با استفاده از آماره MGN مورد بررسی قرار داد.

$$MGN = \frac{\hat{\rho}_{sd}}{\sqrt{\frac{1 - \hat{\rho}_{sd}^2}{N - 1}}} \quad (16)$$

که در آن ρ_{sd} ضریب همبستگی بین S_t و D_t و N تعداد مشاهدات است. مقدار MGN محاسبه شده با t جدول با درجه آزادی $N-1$ مقایسه می‌شود (دیبولد ماریانو، 2002). نتایج آماره‌های فوق در جداول زیر مشاهده می‌شود.

جدول (5): مقایسه عملکرد مدل‌های پیش‌بینی

CSP	CDCP	TIC	MAPE	MAE	RMSE	روش پیش‌بینی
0.484	0.403	0.814	243.37	0.6288	0.1460	ARIMA(10, 9)
0.490	0.450	0.708	214.93	0.6104	0.1436	GARCH
0.620	0.651	0.462	168.41	0.1085	0.1343	ANFIS

منبع: یافته‌های تحقیق

¹ Diebold, and Mariano

همانطور که مشهود است و انتظار می‌رفت مدل شبکه عصبی فازی در تمامی معیارهای فوق از دقت پیش‌بینی بهتری برخوردار است. این مدل توانسته 62 درصد علامت بازده را درست پیش‌بینی کند، این در حالی است که مدل خطی ARIMA تنها 48 درصد توانایی تشخیص علامت بازده را داشته است. همچنین مدل غیرخطی ANFIS توانسته بیش از 65 درصد تغییر علامت‌ها در بازده را شناسایی کند که در مقایسه با دو روش ARMA و GARCH که به ترتیب 40 و 45 درصد تغییر علامت‌ها را پیش‌بینی کرده‌اند موفق‌تر بوده است.

جدول (6): نتایج آزمون MGN

	ARIMA	GARCH	ANFIS
ARIMA		-----	-----
GARCH	-3.95013		-----
ANFIS	-4.03421	-1.09314511	

منبع: یافته‌های تحقیق

با توجه به نتایج جدول ۶ اختلاف معنی‌داری در پیش‌بینی روش‌های خطی ARAM و غیرخطی ANFIS و GARCH وجود دارد اما در میان روش‌های غیر خطی تفاوت چندانی در پیش‌بینی‌ها مشاهده نمی‌شود که با توجه به ماهیت غیر خطی داده‌ها قابل پیش‌بینی بود.

7- نتیجه‌گیری

معمولا برای پیش‌بینی از روش‌های آماری چون رگرسیون خطی یا چند جمله‌ای، مدل‌های ساختاری، مدل‌های سری زمانی مانند خود رگرسیون میانگین متحرک (ARIMA)، نمو هموار و از این قبیل استفاده می‌کنند اما این مدل‌ها با ضعف‌هایی همراهند که به محقق اجازه نمی‌دهد تا عوامل پیچیده و غیر خطی موثر بر پیش‌بینی را در نظر بگیرد. علاوه بر این اخیرا اثبات شده که بسیاری از مشاهدات سری زمانی اقتصادی غیر خطی بوده و تخمین مدل‌های خطی برای مسائل پیچیده دنیای واقعی همیشه رضایت‌بخش نیست. همچنین پیش‌بینی بر اساس مدل‌های غیر خطی اقتصادسنجی نیز با محدودیت‌هایی زیادی همراه است. از این رو استفاده از تکنیک‌های غیر خطی برای پیش‌بینی سری‌های زمانی روز به روز در حال گسترش بوده است. ترکیب شبکه‌های عصبی مصنوعی و منطق فازی که

شبکه‌های عصبی فازی نامیده می‌شود جدیداً به عنوان روشی برای تقریبی غیر خطی استفاده می‌شود و دارای محاسن زیادی در پیش‌بینی، طبقه بندی، خوشه بندی و سایر تکنیک‌های بهینه‌سازی است. در این مطالعه ابتدا با مدل‌سازی دو روش خطی ARIMA و غیر خطی GARCH برای سری زمانی بازدهی قیمت طلا و با استفاده از پسماند مدل‌های مذکور، آزمون BDS را برای بررسی غیر خطی و آشوبناک بودن سری بازدهی روزانه شاخص سهام به کار گرفتیم. سپس با طراحی یک شبکه عصبی فازی که انعطاف پذیری لازم در پیش‌بینی روابط خطی و غیر خطی بین متغیرها را دارد سعی کردیم تا کارایی این مدل را در مقایسه با روش ARIMA و GARCH در پیش‌بینی بازدهی روزانه طلا بسنجیم. با استفاده از معیارهای ارزیابی RMSE، MAE، MAPE و TIC و همچنین CSP و CDCP به مقایسه‌ی نتایج دو مدل پرداختیم که در تمام این شاخص‌ها مدل شبکه عصبی فازی نسبت به مدل ARIMA و GARCH از عملکرد بهتری برخوردار بود. همچنین با استفاده از آماره MGN معنی‌داری اختلاف در پیش‌بینی مدل‌های خطی و غیرخطی آزمون شد که نتایج حاکی از معنی‌دار بودن اختلاف در نتایج روش‌های غیرخطی نسبت به روش خطی ARIMA بود اما روش‌های غیرخطی در پیش‌بینی‌های خود تفاوت چندانی نشان نمی‌دهند.

فهرست منابع

۱. قدیمی، محمدرضا. مشیری، سعید (1381). مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN). پژوهش‌های اقتصادی ایران، 12: 97-125.
۲. رئوفی، علی (1392). شناسایی سیستم مولد داده‌های بورس اوراق بهادار تهران، مدل‌سازی و پیش‌بینی با استفاده از محاسبات نرم، پایان نامه کارشناسی ارشد، دانشگاه شهید چمران اهواز، دانشکده اقتصاد و علوم اجتماعی
۳. زراءزاد، منصور، رئوفی، علی و کیانی، پویان (1391). ارزیابی و مقایسه عملکرد مدل خود رگرسیون میانگین متحرک انباشته و شبکه عصبی فازی برای پیش‌بینی روزانه قیمت طلا، اولین کنفرانس بین‌المللی اقتصادسنجی، روش‌ها و کاربردها. سنندج، دانشگاه آزاد اسلامی واحد سنندج.
۴. حمید، شهرام (1387). پیش‌بینی نرخ تورم در اقتصاد ایران با استفاده از شبکه‌های عصبی مصنوعی پویا، پایان نامه کارشناسی ارشد، دانشگاه شهید چمران اهواز، دانشکده اقتصاد و علوم اجتماعی.
5. Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Economics*; 31: 307-327.
6. Brock, W. A., W. Dechert., J. Scheinkman (1987). A Test for Independence Based on the Correlation Dimension. Working paper, University of Wisconsin at Madison, University of Houston, and University of Chicago.
7. Brooks, C. (2008). *Introductory Econometrics for Finance*. Second Edition, Cambridge University Press.
8. Church, k. b., Curram S. P. (1996). Forecasting consumers' expenditure: A comparison between econometric and neural network models. *International Journal of Forecasting*, 12, 2, 255-267.
9. Diebold. F., Mariano R. (2002). Comparing predictive accuracy. *Journal of Business and Economic Statistics* 20, 134-144.
10. Engle F. R. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 987-1007.
11. Fahimifard, S. M., Salarpour, M., Sabouhi, M., Shirzady, S. (2009). Application of ANFIS to Agricultural Economic Variables Forecasting Case Study: Poultry Retail Price, *Artificial Intelligence*, 2(2): 65-72.

12. Gerlow, M., Irwin, S., Liu, T. (1993). Economic Evaluation of Commodity Price Forecasting Models. *International Journal of Forecasting*, 9:387- 421.
13. Granger, C. W. J., Newbold, P. (1986). *Forecasting economic time series*. Orlando: Academic Press.
14. Gujarati D. (2008). *Basic Econometrics*. 5th Edition . Mc-Graw-Hill.
15. Haykin, S. (1994), *Neural Networks: a Comprehensive Foundation*. Macmillan, New York.
16. <http://www.gold.org>
17. Johnston k., Scott, E. (2000). GARCH Models and The Stochastic Process Underlying Exchange Rate Price Change. *Journal of Financial and Strategic Decisions*, Vol. 2. pp. 13-24.
18. Leitch, G. and Tanner, J.E. (1991). Economic Forecast Evaluation: Profits versus the Conventional Error Measures. *The American Economic Review (AER)*, 81(3), 580 - 90.
19. Parisi, A., Parisi, F., Díaz, D. (2008). Forecasting gold price changes: Rolling and recursive neural network models, *Journal of Multinational Financial Management*, Elsevier, vol. 18(5), pages 477-487, December.
20. Pesaran, M. H., Timmerman, A. (1992). A Simple Nonparametric Test of Predictive Performance. *Journal of Business & Economic Statistics* 10, 4, 461-465.
21. Portugal, N. S. (1995), *Neural networks versus time series Methods: A Forecasting Exercises*, 14th International Symposium on Forecasting, Sweden.
22. Tully, E., Lucey, B. M. (2007). A power GARCH examination of the gold market. *Research in international business and finance*. 21(2), 316-320.
23. Yayar, M., Hekim, M., Yelmaz, V., Bakirci, F. (2011). A comparison of ANFIS and ARIMA techniques in the forecasting of electric energy consumption of Tokat province in Turkey.
24. Zarranezhad, M., Raofifi, A., Kiyani, P. (2012). Evaluation and comparison of performance of ANFIS and ARIMA in forecasting the daily gold prices, *The First international conference on econometrics and methods applications*.
25. Zhang, G., Hu, M.Y. (1998). Neural Network Forecasting of the British Pound/US Dollar Exchange Rate, *International Journal of Management Science*, 26(4): 495–506.
26. Zhang, G., Hu, M.Y. (2001). A Simulation Study of Artificial Neural Networks for Nonlinear Time- Series Forecasting. *Comput. Oper. Res.* 28, pp. 381- 396.
27. Zhang, G., Hu, M.Y. (2004). Forecasting with Artificial Neural Networks: The state of the Art, *Neurocomputing* 56, pp. 205- 232.