

فصلنامه پژوهش‌های اقتصادی ایران / شماره ۲۱ / زمستان ۱۳۸۳ / صفحات ۶۷-۹۰

آزمون آشوب^۱ و پیش‌بینی قیمت‌های آتی نفت خام

دکتر سعید مشیری*

فائزه فروتن

تاریخ ارسال: ۱۳۸۳/۱/۲۲ تاریخ پذیرش: ۱۳۸۳/۵/۵

چکیده

این مقاله به امکان سنجی وجود آشوب در ساختار سیستم مولد قیمت نفت خام شاخص *WTI* طی دوره ۴ آوریل ۱۹۸۳ تا ۱۳ ژانویه ۲۰۰۳ می‌پردازد. به این منظور از تخمین نمای لیاپانوف و بُعد همبستگی به عنوان آزمون‌های مستقیم آشوب و آزمون‌های *BDS* و شبکه عصبی جهت بررسی غیرخطی بودن ساختار سیستم استفاده شده است. نتایج تخمین نمای لیاپانوف و بُعد همبستگی، وجود آشوب در سری زمانی را تأیید کرده و تخمین آماره *BDS* و شبکه عصبی، بر غیرخطی بودن سیستم مولد قیمت روزانه نفت اشاره داشتند. در بخش پایانی یک مدل شبکه عصبی مصنوعی برای پیش‌بینی قیمت‌های آتی نفت خام طراحی و با نتایج پیش‌بینی مدل خطی *ARMA* و غیرخطی *GARCH* مقایسه شد. نتایج حاصل نشان داد مدل شبکه عصبی مورد استفاده نسبت به دو مدل *ARMA* و *GARCH* از قدرت پیش‌بینی بهتری برخوردار است.

واژه‌های کلیدی: آشوب، شبکه‌های عصبی مصنوعی، قیمت نفت خام، مدل‌های غیرخطی، *ARMA*، *GARCH*.

1. Chaos

* به ترتیب، عضو هیئت علمی دانشکده اقتصاد دانشگاه علامه طباطبائی و کارشناس ارشد اقتصاد.

e-mail: smoshiri@mun.ca

e-mail: foroutanfa@yahoo.com

۱. مقدمه

قیمت نفت در بازارهای مالی از مهمترین متغیرهایی است که از یک‌سو، بر ساز و کار اقتصاد کشورهای صادرکننده و واردکننده نفت و از دیگر سو، در فرایند مدیریت و تخمین ریسک مالی پرتفوی سهام شرکت‌های سرمایه‌گذاری مؤثر است. بنابراین، شناخت ساختار قیمت این کالا و مدل‌سازی آن همواره مورد توجه پژوهش‌های اقتصادی بوده و تلاش‌هایی نیز برای بررسی علت نوسانات و پیش‌بینی آن صورت گرفته است.

در مدل‌های ساختاری بیان رفتار قیمت نفت، ملاحظات مربوط به تغییرات عرضه و تقاضا و ائتلاف و شیوه رفتار اعضای اوپک با یکدیگر در نظر گرفته می‌شوند که از آن جمله می‌توان به تحقیق بیکن (Bacon, 1991) اشاره داشت که در آن دو بخش عرضه و تقاضای نفت و عوامل مؤثر بر هر بخش به طور جداگانه بررسی و در کنار آن به محدودیت‌هایی که پژوهشگر ممکن است در تحلیل هر یک از این بخش‌ها با آن روبرو شود، اشاره شده است. لیائو و لین (Liao & Lin, 1995) با استفاده از یک مدل ساختاری شامل متغیرهای ذخایر نسبی نفت خاورمیانه و وقفه آن، نرخ تغییر در پالایش نفت خام جهان، نرخ تغییر در ذخایر نفت جهان در سال قبل، نرخ تغییر در تولید نسبی اوپک، نرخ تغییر در ذخایر گاز جهان و سهم تولید نسبی عربستان، زمان وقوع تکانه بعدی قیمت در بازار نفت را پیش‌بینی می‌کنند. پیندایک (Pindyck, 1999) برای پیش‌بینی بلندمدت قیمت نفت با استفاده از روش فیلتر کالمن^۱ رابطه قیمت نفت را بر حسب وقفه اول، متغیر زمان و متغیرهای حالت "میزان پایه ذخیره منابع"، "هزینه نهایی" و "تقاضا" بیان می‌کند. اصولاً با وجود اینکه مدل‌های چندمتغیره در فهم بهتر و دقیق ساختار سیستم مولد سری توانا هستند ولی تنها برازش خوبی از سری زمانی ارائه داده و در پیش‌بینی‌های بلندمدت موفق نخواهند بود. از دلایل این امر می‌توان به امکان نادیده گرفتن بعضی متغیرهای مهم و یا تخمین نادرست رابطه بین قیمت نفت و متغیرهای توضیحی آن اشاره داشت. همچنین، به منظور پیش‌بینی قیمت نفت به عنوان یک متغیر وابسته، ابتدا باید پیش‌بینی هر یک از متغیرهای توضیحی محاسبه و سپس، به مدل قیمت وارد شوند و بنابراین، وجود هر نوع خطای پیش‌بینی متغیرهای توضیحی، بر خطای پیش‌بینی قیمت نفت می‌افزاید (Chatfield, 2001).

از آنجا که شناخت رفتار قیمت نفت خام به دلیل پیچیدگی‌های ناشی از تأثیر عوامل متعدد و نوسانات گسترده به ویژه پس از شوک‌های قیمتی دهه‌های ۷۰ و ۸۰ میلادی تا حدی مشکل است، اغلب برای پیش‌بینی آن از مدل‌های خودرگرسیون تک متغیره استفاده می‌شود که در آنها سری زمانی به صورت ترکیبی از روند گذشته به اضافه یک "جزء همراه" 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 غیرتصادفی است. از جمله پژوهش‌های انجام شده در این زمینه در بازار نفت می‌توان به مقاله ابوسدرا

1. Kalman Filter.

(Abosedra, 1997) اشاره کرد که در آن از یک مدل خودرگرسیون واریانس شرطی (EGARCH) برای پیش‌بینی رفتار قیمت نفت استفاده شده است. اما طبق نظریه آشوب، ممکن است که این "جزء به ظاهر تصادفی" از یک فرایند معین^۱ غیرخطی پیروی کند و به وسیله یک معادله یا سیستم معادلات معین قابل بیان باشد. در واقع، نظریه آشوب به جستجوی نظم در رفتار به ظاهر تصادفی برخی سیستم‌های دینامیک غیرخطی معین می‌پردازد. در یک سیستم آشوبناک، نوسانات به ظاهر تصادفی از مکانیزم درونی سیستم غیرخطی مولد داده‌ها نتیجه شده و ارتباطی با وقوع تکانه‌های خارجی ندارد. بنابراین، می‌توان تغییرات نامنظم روند برخی متغیرهای اقتصادی مانند GDP و یا تغییرات بزرگ در بازار سهام نظیر تحولات اکتبر ۱۹۸۷ را نتیجه وجود ساختار آشوبناک در آنها دانست.

در این پژوهش ساختار سیستم مولد قیمت نفت بررسی و سپس، مدلی برای پیش‌بینی روند آتی آن ارائه خواهد شد. سازمان‌دهی مقاله به شرح زیر است. پس از توضیحاتی پیرامون ویژگی‌های آماری سری زمانی قیمت نفت در قسمت دو، برآوردهای مدل‌های خطی و غیرخطی در بخش سه ارائه خواهد شد. در قسمت چهارم، آزمون‌های آشوب و در بخش پنج پیش‌بینی با یک مدل شبکه عصبی و مقایسه آن با سایر مدل‌ها ارائه خواهد شد. نتیجه‌گیری بخش پایانی مقاله خواهد بود.

۲. داده‌ها و ویژگی‌های سری زمانی

داده‌های مورد استفاده این پژوهش، قیمت روزانه نفت بازار معاملات آتی کالای نیویورک (NYMEX)^۲، از ۴ ژوئیه ۱۹۸۳ تا ۱۳ ژانویه ۲۰۰۳ است که در مجموع ۵۱۶۱ مشاهده را در بر می‌گیرد. نمودار (۱) روند قیمت نفت و جدول (۱) ویژگی‌های آماری آن را در این دوره ۲۰ ساله نشان می‌دهند. به طور خلاصه می‌توان به موارد زیر در مورد روند تغییرات قیمت نفت در این دوره اشاره کرد:

(۱) میانگین قیمت نفت در این دوره ۲۱/۷۵ دلار با انحراف معیار ۵/۵۳ دلار بوده است. علامت مثبت شاخص آماری Skewness حاکی از کجی توزیع قیمت نفت به سمت راست، مقدار شاخص آماری Kurtosis حاکی از پهن تر بودن توزیع قیمت نفت نسبت به توزیع نرمال و مقدار آماره Jarque-Bera بیانگر غیرنرمال بودن توزیع قیمت نفت است.

(۲) طی دوره مورد بررسی، دو رویداد افزایش عرضه اوپک در نوامبر سال ۱۹۸۵ و جنگ خلیج فارس در اکتبر ۱۹۹۰ تأثیر قابل ملاحظه‌ای بر بازار نفت و قیمت آن ایجاد کرده‌اند.

1. Deterministic.
2. New York Merchantile Exchange.

آزمون آشوب و پیش‌بینی قیمت‌های آتی نفت خام


۳) قیمت نفت دارای یک روند افزایشی یا کاهش‌ی منظم نیست. صرف نظر از تکانه سال‌های ۱۹۸۵ و ۱۹۹۰ که تغییرات شدیدی در سطح قیمت ایجاد کرد، روند کاهش‌ی یا افزایش‌ی خاصی برای مدت زمانی در حدود ۱۵ سال دیده نمی‌شود. به بیان دیگر، برای یک دوره ۱۵ ساله، قیمت نفت خام دوره‌های پرتلاطمی را پشت سر گذاشته اما همیشه تمایلی به برگشت به سمت میانگین از خود نشان داده است.

۴) شدت نوسان‌ها و دوره‌های آن ثابت و یکسان نیستند. این نکته وجود ساختاری غیرخطی را در سری مطرح می‌سازد و استفاده از مدلی را پیشنهاد می‌کند که تغییر واریانس در طول زمان را لحاظ نماید.

جدول ۱- خصوصیات آماری سری زمانی قیمت روزانه نفت بازار معاملات آتی کالای نیویورک (۱۹۸۳-۲۰۰۳)

Jarque-Bera	کشیدگی	چولگی	انحراف معیار	میانگین
۲۶۲/۸(۰/۱۰)	۲/۳۷	۰/۴۵	۵/۵۳	۲۱/۷۵

نمودار ۱- قیمت روزانه نفت در بازار مبادلات کالای نیویورک (۱۹۸۳-۲۰۰۳)



برای بررسی مانایی فرایند ایجادکننده داده‌ها از آزمون دیکی- فولر تعمیم یافته (ADF) استفاده می‌شود. در این آزمون، یک جزء ثابت به همراه یک تا سه وقفه در نظر گرفته شده است. مقدار این آماره برای قیمت نفت برابر با ۲/۸۳ است و با توجه به مقادیر بحرانی، نمی‌توان وجود ریشه واحد را در سطح ۱ و ۵ درصد رد کرد. بنابراین، طبق نتیجه آزمون دیکی - فولر تعمیم یافته، قیمت نفت در این دوره نامانا بوده و نیاز به تفاضل‌گیری دارد. برای اطمینان از اینکه تکانه سال ۱۹۸۵ عامل پذیرش فرض ریشه واحد نبوده، آزمون پرون^۱ (۱۹۸۹) که اثر این شوک ساختاری در آن لحاظ شده نیز به کار گرفته می‌شود. مقدار بحرانی آماره t محاسبه شده جدول پرون به ازای $\lambda=0/1$ در سطح ۵٪ برابر است با $-۳/۶۸$ و آماره محاسبه شده برای سری زمانی قیمت نفت در این پژوهش -۴ است که بزرگتر از حد بحرانی جدول پرون است. بنابراین، استفاده از آزمون تغییرات ساختاری پرون نشان می‌دهد که با لحاظ شوک نوامبر سال ۱۹۸۵، سری زمانی مانا بوده و دلیلی برای تفاضل‌گیری وجود نخواهد داشت.

۳. برآورد مدل‌های خودرگرسیون ARMA و GARCH

۱-۳. مدل ARMA

با تصریح یک مدل $ARMA(m, n)$ مناسب که به صورت زیر نشان داده می‌شود:

$$\phi(B)P_t = \theta(B)\varepsilon_t$$

که m و n تعداد وقفه های قیمت نفت و جزء اخلاص، و ϕ و θ ضرایب آنها هستند، می‌توان ساختار خطی موجود در سری زمانی را استخراج کرده و انتظار داشت پسماندهای حاصل مستقل از یکدیگر و دارای توزیعی یکسان باشند. در این مطالعه با به کارگیری روش باکس- جنکینز، مدل $ARMA(1, 3)$ برای برآورد قیمت نفت انتخاب شد. تخمین مدل $ARMA$ در جدول (۲) آورده شده است. طبق آزمون همبستگی سریالی، در پسماندهای حاصل از این مدل هیچ گونه همبستگی سریالی وجود ندارد. با توجه به وجود نوسانات نامنظم در روند قیمت نفت، وضعیت همسانی واریانس این مدل به وسیله آزمون ARCH-LM بررسی می‌شود. با انجام این آزمون بر پسماندهای مدل $ARMA$ ، فرض همسانی واریانس رد می‌شود. بنابراین، استفاده از مدل واریانس شرطی در تخمین مناسب‌تر است. تغییرات واریانس شرطی یک مدل $GARCH(1, 1)$ با زمان را می‌توان طبق رابطه زیر نوشت:

$$P_t = \eta P_{t-1} + \varepsilon_t$$

$$\sigma_t^2 = \gamma + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2$$

1. Perron.

آزمون آشوب و پیش‌بینی قیمت‌های آتی نفت خام

که P_{t-1} وقفه اول متغیر و σ_{t-1} وقفه اول واریانس است. در این تحقیق با تکیه بر مقدار p-value گزارش شده برای آماره F، مدل GARCH(2,1) انتخاب شده است که تخمین مدل فوق در جدول (۳) آورده شده است.

جدول ۲- برآورد مدل ARMA (1,3) برای قیمت نفت (۱۹۸۳-۲۰۰۳) *

$$P_t = \alpha_0 + \alpha_1 D_1 + \phi_1 P_{t-1} + \theta_1 \varepsilon_{t-2} + \theta_2 \varepsilon_{t-3} + \zeta_t$$

α_0	α_1	ϕ_1	θ_1	θ_2
۲۳/۱۱	-۱/۳۷	۰/۹۹	-۰/۰۶	-۰/۰۸
(۱۲/۱۱۶)	(-۴/۴۳)	(۶۱۷/۰۳)	(-۲/۳۹)	(-۲/۸۶)
Serial correlation	ARCH-LM	AIC	BIC	SSE
۰/۵	۶۶/۹۶	۱/۵۱	۱/۵۲	۱۳۷۳/۶۹
P-value (۰/۶۰)	(۰/۰۰)			

* ارقام داخل پرانتز در ردیف بالا مقادیر آماره t و در ردیف پایین P-Value هستند و D متغیر موهومی برای شوک سال ۱۹۸۵ است.

جدول ۳- برآورد مدل GARCH(2,1) برای قیمت نفت (۱۹۸۳-۲۰۰۳)

$$\sigma_t^2 = \omega + \beta_0 \sigma_{t-1}^2 + \beta_1 \sigma_{t-2}^2 + \alpha_0 \varepsilon_{t-1} + \zeta_t$$

Ω	β_0	β_1	α_0
۰/۰۰۲	۰/۱۷۴	۰/۶۷۶	۰/۱۴۸
(۳/۵۶۶)	(۲/۸۷۲)	(۱۲/۰۱۰)	(۸/۰۸۹)
ARCH-LM	AIC	SIC	SSE
۰/۲۹۴	۰/۹۴۷	۰/۹۵۸	۱۳۹۱/۳۳۳
p-value: (۰/۵۸۷)			

* ارقام داخل پرانتز در ردیف بالا مقادیر آماره t و در ردیف پایین P-Value هستند.

در قسمت بعد به کنکاش بیشتر در مورد خصوصیات آماری این متغیر می پردازیم تا امکان پیروی آن از یک فرایند آشوبناک نیز مشخص شود

۴. آشوب

یک فرایند آشوبناک^۱، فرایندی پویا، غیرخطی و معین^۲ است در حالیکه خروجی آن ظاهری پیچیده و تصادفی دارد. با توجه به تعریف براک (Brock)، سری زمانی $\{a_t\}$ یک سری معین آشوبناک خواهد بود اگر سیستم مولدی به صورت (h, F, X_0) وجود داشته باشد به طوری که h تابعی باشد که R^n را به R می نگارد (در اینجا منظور از n بعد سیستم اصلی و R مجموعه اعداد حقیقی است)، F تابعی است که R^n را به R^n می نگارد (به عبارت بهتر، F همان بیان ریاضی مدل مفروض است) و روابط زیر برقرار است:

$$a_t = h(X_t)$$

$$X_t = F(X_{t-1})$$

X_0 شرایط اولیه سیستم در زمان $t = 0$ است. در اینجا نگاشت F معین است، تمام مسیرهای زمانی در روی یک جاذب جای گرفته‌اند و دو مسیر^۳ مجاور با گذشت زمان از یکدیگر به صورت نمایی دور می‌گردند. مسیرهای حرکت سری‌های آشوبناک در فضای حالت^۴ به سوی یک نقطه یا یک سیکل محدود^۵ همگرا نمی‌شوند، بلکه جاذب‌هایی را با اشکال هندسی خاص که جاذب پیچیده^۶ نام دارند بوجود می‌آورند. واگرایی مسیرهای زمانی مجاور از ویژگی‌های سیستم‌های آشوبناک است و به وسیله نمای لیاپانوف مثبت مشخص می‌شود. از دیگر ویژگی‌های مهم سیستم‌های آشوبناک، فراکتال بودن بُعد جاذب آنهاست، به این معنی که بُعد جاذب یک سیستم دینامیک غیرخطی آشوبناک، عددی غیرصحیح است.^۷

تشخیص آشوب در سری زمانی به دو دلیل دارای اهمیت است: اول اینکه، سیستم آشوبناک به رفتار پیچیده‌ای می‌انجامد که به نظر تصادفی می‌رسد، حال آنکه تصادفی نیست. دیگر اینکه، اگرچه آشوب غیرقابل پیش‌بینی است، این واقعیت که از یک سیستم معین و غیرخطی پدید آمده آن را به طور کامل از سیستم‌های تصادفی متمایز می‌کند.

موضوع آشوب در اقتصاد در بسیاری از پژوهش‌های پیشین بررسی شده است که می‌توان به مقالات Barnett, 1997. Hsieh, 1991. Ninni & Panas, 2000. Frank & Stengos, 1988.

1. Chaotic
2. Deterministic
3. Trajectory
4. Phase space
5. Limit cycle
6. Strange attractor

۷. برای آشنایی بیشتر با مفهوم آشوب و ویژگی‌ها و کاربردهای آن به (Baumol & BenHabib (1989) و Brock (et.al, 1992) و مشیری (۱۳۸۱) مراجعه کنید.

در زمینه آشوب در مورد قیمت نفت خام نیز مطالعاتی مانند Adrangi et.al, 2001 و ابریشمی، معینی و احراری (۱۳۸۱) انجام شده است. در ادامه، برخی آزمون‌های موجود برای تشخیص وجود فرایند آشوبناک در سیستم مولد قیمت نفت مورد بررسی قرار خواهد گرفت.

۴-۱. تخمین نمای لیپانوف

از ویژگی‌های یک سیستم‌های آشوبناک، حساسیت نسبت به تغییر در شرایط اولیه است. چنانچه در شرایط اولیهٔ چنین سیستمی، تغییری جزئی روی دهد اثر این تغییر با گذشت زمان پررنگ‌تر خواهد شد تا جایی که به ایجاد مسیر زمانی می‌انجامد که با مسیر زمانی قبلی کاملاً متفاوت است. این خاصیت سیستم‌های آشوبناک به اثر پروانه‌ای^۱ مشهور است و با تخمین نمای لیپانوف قابل بررسی است. نماهای لیپانوف متوسط نرخ همگرایی یا واگرایی نمایی مسیرهای مجاور در فضای حالت هستند و برای اندازه‌گیری حساسیت سیستم نسبت به تغییر در شرایط اولیه به کار می‌روند. مقدار مثبت نمای لیپانوف از ویژگی‌های یک سیستم آشوبناک است؛ در مقابل، نمای لیپانوف منفی بیانگر وضعیت یک سیستم دینامیک میرا است (Wolf, 1985).

چنانچه معادلات مربوط به یک سیستم معین در اختیار باشد برای تخمین نمای لیپانوف از روش ساده‌ای به نام روش تابعی^۲ می‌توان استفاده کرد، ولی این روش در صورت ناشناخته بودن معادلهٔ سیستم مولد داده‌ها کارگشا نیست. در این پژوهش، برای محاسبهٔ نمای لیپانوف از روش "بُعدی"^۳ به کمک الگوریتم Wolf استفاده خواهد شد. نمای لیپانوف را می‌توان به ازای بُدهای مختلف محاسبه کرد و وقتی صحبت از یک نما می‌شود، منظور بزرگ‌ترین آنهاست. برای محاسبه، از میان نقاط موجود در فضای فاز بازسازی شده m بُعدی، جفت بردارهایی که فاصله اقلیدسی شان از یکدیگر کمتر از ε (مقداری معین و کوچک) است، انتخاب می‌شوند:

$$r_0 = |X_i - X_j| < \varepsilon$$

سپس، میزان واگرایی این دو نقطه طبق رابطهٔ:

$$d_n = \frac{|X_{i+n} - X_{j+n}|}{|X_i - X_j|}$$

1. Butterfly effect
2. Functional.
3. Dimensional.

محاسبه می‌شود که در آن، n گام زمانی^۱ نامیده می‌شود. چنانچه مقدار d_n از یک بزرگتر شود، دلالت بر این نکته خواهد داشت که نقاط واقع بر مسیرها نسبت به یکدیگر واگرا خواهند شد. فرمول محاسبه نمای لیپانوف به صورت زیر است:

$$LE(m, n) = \frac{1}{n} \sum_n \log d_n(m; i, j)$$

در جدول (۴) تخمین نمای لیپانوف (LE) آورده شده است. نتایج به دست آمده نشان می‌دهد که ازای تمامی بدها، مقدار نمای لیپانوف عددی مثبت است که بیانگر پیروی قیمت نفت از یک فرایند آشوبناک است.

جدول - ۴. تخمین نمای لیپانوف برای بررسی آشوب در قیمت نفت (۱۹۸۳-۲۰۰۳)

m	ε/σ	LE
۲	۰/۵	۰/۳۷۸۴
۳		۰/۴۵۸۵
۴		۱/۰۷۵۰
۵		۱/۱۶۲۳
۲	۱	۰/۳۸۴۰
۳		۰/۳۶۸۹
۴		۰/۳۵۹۱
۵		۰/۴۲۲۳
۲	۱/۵	۰/۳۳۴۴
۳		۰/۴۷۸۲
۴		۰/۳۸۷۰
۵		۰/۳۴۴۱
۲	۲	۰/۴۲۱۲
۳		۰/۴۳۷۲
۴		۰/۴۵۶۳
۵		۰/۵۰۳۴

1. Time Step.

۲-۴. تخمین بُعد همبستگی

گراسبرگر و پروکاچا (Grassberger and Procaccia, 1983) الگوریتم بُعد همبستگی را برای جستجوی رفتار آشوبناک در سری زمانی پیشنهاد کرده‌اند که این الگوریتم، بُعد سیستم مولد داده‌ها را تخمین می‌زند. کار تحلیل سری زمانی، با سری یک بُعدی به صورت $\{x_t\}_{t=1}^T$ شروع می‌شود که می‌توان آن را به ماتریسی با ابعاد $m \times T$ به شکل زیر تبدیل کرد:

$$X_t = (x_t, x_{t-1}, \dots, x_{t-m+1})^{Transpose}$$

m را embedding dimension می‌نامند. هر ردیف از ماتریس X_t ، یک بردار m تایی (یک نقطه در فضای حالت m -بعدی) است. تعداد این نقاط در فضای فاز از رابطه $N = T - m + 1$ به دست می‌آید.

اگر $\{x_t : t = 1, \dots, T\}$ یک نمونه تصادفی از متغیرهایی باشد که مستقل از یکدیگر و دارای توزیع احتمال یکسانند، آن‌گاه به ازای مقادیر مشخص m و ε خواهیم داشت:

$$C_m(\varepsilon) = C_1(\varepsilon)^m \quad T \rightarrow \infty$$

$$C_m(\varepsilon) = \lim_{T \rightarrow \infty} \{ \text{the number of } (i,j) \text{ for which } |X_i^m - X_j^m| \leq \varepsilon \} / T^2$$

$C_m(\varepsilon)$ همبستگی جمعی^۱ یا تعداد نقاط موجود در فضای m بُعدی است که فاصله ای کمتر از مقدار کوچک و معین ε از یکدیگر دارند. اگر سری زمانی از یک فرایند تصادفی نتیجه شده باشد، با افزایش embedding dimension نقاط موجود در فضای حالت m بُعدی، در تمام جهات پراکنده خواهند شد ولی اگر سری از یک فرایند معین نتیجه شده باشد، نقاط به سمت زیرمجموعه‌ای از فضای حالت جذب می‌شوند. در این وضعیت، با افزایش embedding dimension، بُعد جاذب در فضای حالت از محدوده‌ای فراتر نخواهد رفت و عددی کوچکتر از m خواهد بود. بُعد همبستگی طبق رابطه زیر به دست می‌آید.

$$D^m = \lim_{\varepsilon \rightarrow \infty} \frac{\log C_m}{\log \varepsilon}$$

در یک سیستم آشوبناک به ازای مقدار مشخص ε ، با افزایش m ، از تعداد نقاطی که در فضای حالت فاصله‌ای کمتر از ε دارند کاسته شده، در نتیجه، مقدار بُعد همبستگی به یک حد اشباع^۲ همگرا می‌شود، در حالی که در یک سیستم تصادفی، با افزایش m ، D^m نیز افزایش می‌یابد. تخمین بُعد

1. Correlation Integral or Correlation Sum.
2. Saturation limit.

همبستگی به وجود نویز در مشاهدات حساس است (Harrison et.al, 1999). بنابراین، در این پژوهش تخمین بُعد همبستگی برای قیمت نفت پس از حذف نویز با استفاده از روش Wavelet و Hodrick– Prescott نیز برآورد شده است (جدول ۵).

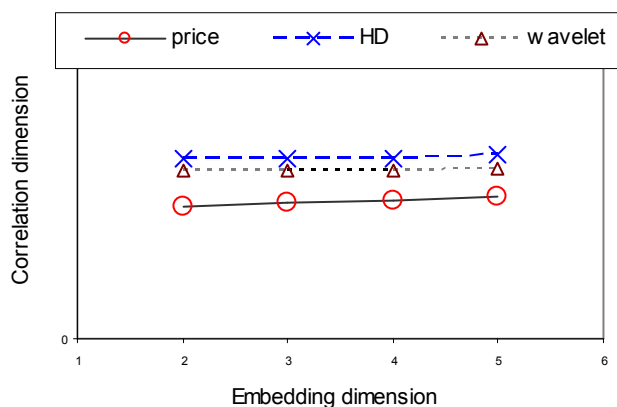
جدول ۵- تخمین بُعد همبستگی برای بررسی آشوب در قیمت نفت (۱۹۸۳-۲۰۰۳)

نام سری	۲	۳	۴	۵
بُعد همبستگی برای داده‌های خام	۰/۴۱	۰/۴۲	۰/۴۳	۰/۴۴
حذف اثر نویز با Hodrick-Prescott	۰/۵۶	۰/۵۶	۰/۵۶	۰/۵۷
حذف اثر نویز با wavelet	۰/۵۲	۰/۵۲	۰/۵۲	۰/۵۳

مقادیر بُعد همبستگی نشان می‌دهند که با افزایش m ، مقدار D^m در مشاهدات خام و همچنین، مشاهدات پس از حذف نویز، ثابت باقی می‌ماند.

اگرچه در بسیاری از تحقیقات اقتصادی روش تخمین بُعد همبستگی به عنوان یک آزمون قوی جستجوی آشوب شناخته شده است، استفاده از این روش نیازمند در اختیار داشتن حجم بالای مشاهدات است. رامسی (Ramsy) و دیگران (۱۹۹۰) نشان داده‌اند که تخمین بُعد همبستگی در شرایط محدودیت حجم داده ممکن است تا حدی گمراه کننده باشد. همچنین، باید در نظر داشت که روش تخمین بُعد همبستگی آزمون آماری نبوده و صرفاً بر پایه تحلیل نموداری استوار است و به همین دلیل در کنار استفاده از تخمین بعد همبستگی از آزمون آماری BDS نیز بهره گرفته می‌شود.

نمودار ۲- تخمین بُعد همبستگی برای بررسی آشوب در ساختار قیمت نفت (۱۹۸۳-۲۰۰۳) برای داده‌های خام، داده‌های فیلتر شده با روش Wavelet و روش Hodrick-Prescott (HD)



۳-۴. آزمون BDS

براک، دیچرت و شاینکمن (Scheinkman و Dechert ، Brock)، در سال ۱۹۸۷ آزمون آماری که بر مبنای فرض استقلال و توزیع یکسان (IID) اعضای سری زمانی است، ارائه دادند. در این بخش از این آزمون به منظور بررسی وضعیت ساختار سیستم به لحاظ خطی یا غیرخطی بودن استفاده می‌شود. آماره BDS به صورت زیر تعریف می‌شود:

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

که در آن: $\sigma_{m,T}$ انحراف استاندارد عبارت داخل براکت، m بُعد و ε مقداری 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 فرض صفر و دلیلی بر وجود وابستگی (از نوع خطی و یا غیرخطی) در ساختار سیستم خواهد بود و مقدار نزدیک به صفر آن به معنی پذیرش فرض صفر و تأییدی بر استقلال و توزیع یکسان مشاهدات است. در این آماره، انتخاب مقدار ε دارای اهمیت بسیاری است و اغلب به صورت ضربی از انحراف استاندارد سری زمانی انتخاب می‌شود. به منظور استفاده از آماره BDS به عنوان آزمونی برای بررسی خطی بودن ساختار سیستم مولد قیمت نفت، ابتدا، با اجرای مدل $ARMA(1,3)$ کلیه اجزای خطی فرایند را استخراج کرده سپس، آماره BDS برای پسماندهای آن محاسبه و با مقادیر بحرانی مقایسه می‌شوند. اگر ساختار سیستم مولد داده‌ها خطی باشد، فرض صفر مبنی بر اینکه پسماندهای مدل خطی، IID هستند پذیرفته می‌شود. اما اگر سیستم مولد داده‌ها غیرخطی باشد، پسماندهای مدل خطی IID نبوده در نتیجه، فرض صفر رد خواهد شد. آزمون BDS می‌تواند روی پسماندهای مدل واریانس شرطی (ARCH-GARCH) نیز اعمال شود که در صورت پذیرفته شدن فرض صفر می‌توان گفت مدل واریانس شرطی، ساختار غیرخطی موجود در سری را توضیح داده است در غیر این صورت، امکان وجود فرایند آشوبناک در ساختار سری وجود خواهد داشت. (Hsieh, 1989)، (Hsieh, 1991)، (Brock et al., 1993)

در این پژوهش از پسماندهای مدل خطی $ARMA(1,3)$ و غیرخطی $GARCH(2,1)$ برای انجام آزمون BDS استفاده شده است. مقدار محاسبه شده آماره آزمون BDS در جدول (۶) آورده شده است. در این جدول، ε برابر با ۰/۵، ۱، ۱/۵ برابر انحراف استاندارد پسماندها است. در تفسیر مقادیر محاسبه شده آماره BDS برای پسماندهای مدل خطی $ARMA$ باید گفت اگر به ازای مقادیر کوچک ε نتوان فرض صفر را رد کرد ولی به ازای مقادیر بزرگتر، فرض صفر رد شود، می‌توان نتیجه گرفت که سری زمانی به مدل‌های غیرخطی تعلق دارد و با نویز همراه است (Medio, 1992).

1. Independent and Identically Distributed.

جدول ۶- آزمون BDS روی پسماند مدل‌های ARMA و GARCH برای قیمت نفت (۱۹۸۳-۲۰۰۳)

مدل	ε/σ			
	m	.۵	۱	۱/۵
ARMA	۲	۱/۲۳	۱/۶۵	۱/۷۰
	۳	۱/۵۳	۳/۵۰	۳/۶۶
	۴	۱/۳۵	۴/۶۰	۵/۴۴
	۵	۱/۰۲	۵/۲۰	۶/۹۹
GARCH	۲	۱/۲۷	۱/۹۲	۱/۶۹
	۳	۱/۶۰	۳/۶۳	۳/۶۲
	۴	۱/۴۳	۴/۷۹	۵/۴۲
	۵	۱/۱۰	۵/۴۵	۷/۰۰


در این جدول مقدار ε برابر با ۰/۵ و ۱/۵ برابر انحراف استاندارد سری در نظر گرفته شده است. مقدار بحرانی معادل ۱/۶۴۵ در سطح ۱۰ درصد است.

طبق جدول و با مراجعه به مقادیر بحرانی، فرض IID بودن پسماندهای مدل خطی را تنها به ازای مقدار $\varepsilon = ۰/۵$ نمی‌توان رد کرد. اگر مدل ARMA انتخاب شده برای بیان ساختار خطی موجود در سری را بهترین مدل فرض کنیم، رد فرض صفر IID بودن، دلیلی بر وجود ساختار غیرخطی (شرط لازم آشوبناک بودن یک سری زمانی) است. از دیگر سو طبق جدول، فرض صفر آماره BDS، برای پسماند مدل غیرخطی GARCH نیز رد شده است. با توجه به تخمین‌های نمای لیاپانوف و بُعد همبستگی و همچنین، وجود ساختار غیرخطی در مشاهدات می‌توان فرض وجود ساختار معین (غیرتصادفی) آشوبناک در سری زمانی قیمت نفت را تأیید کرد. به منظور اطمینان بیشتر از حضور ساختار غیرخطی در سری زمانی در ادامه از آزمون شبکه عصبی نیز استفاده خواهد شد.

۴-۴. آزمون شبکه عصبی

شبکه‌های عصبی، نوعی متفاوت از مدل‌های غیرخطی هستند که با الگوبرداری از رفتار مغز انسان کاربردهای وسیعی در شاخه‌های مختلف علوم از جمله کاربردهای آماری، شناسایی الگوها، تخمین و پیش‌بینی مدل‌ها داشته‌اند. شبکه عصبی مجموعه‌ای از واحدهای محاسبه‌گر به هم مرتبط است که هر کدام یک نورون نام دارند. نورون کوچکترین واحد پردازش اطلاعات بوده و اساس عملکرد شبکه عصبی را تشکیل می‌دهد. شکل (۱) ساختار کلی یک شبکه عصبی مصنوعی را نشان می‌دهد.

شکل-۱. ساختار نورونی با m ورودی



میزان تأثیر ورودی شبکه (x_i) روی خروجی (y_k) به وسیله مقدار وزن (w_{ki}) تعیین می‌شود. این حاصل جمع، ورودی تابع فعال ساز f خواهد بود. به این ترتیب خروجی شبکه با معادله زیر تعریف می‌شود:

$$y_k = f(w x + b)$$

پارامترهای w و b بر اساس انتخاب f و نوع الگوریتم یادگیری قابل تنظیم هستند و تابع محرک f می‌تواند هر تابع انتقالی خطی یا غیرخطی باشد، ولی معمولاً از تابع غیرخطی سیگموئید یا تانژانت هایپربولیک استفاده می‌شود. یادگیری به این معنی است که w و b طوری تغییر کنند که رابطه ورودی x و خروجی y نورون با هدف خاصی مطابقت نماید (Haykin, 1999).

چنانچه بخواهیم شبکه، وظیفه خاصی را انجام دهد، می‌توان به کمک اصلاح مقادیر وزن‌ها (ارتباط بین نورون‌ها)، شبکه را آموزش داد. در تحلیل سری‌های زمانی، شبکه‌های عصبی به عنوان ابزاری برای تقریب توابع غیرخطی پیچیده به کار می‌روند. برای یک مدل شبکه عصبی شامل یک لایه میانی با q نرون، معادله عمومی تخمین و پیش‌بینی به شکل زیر بیان می‌شود:

$$y = F[\beta_0 + \sum_{j=1}^q G(X\gamma_j)\beta_j] \equiv f(X, \theta)$$

در این معادله، γ خروجی نهایی مدل، F و G توابع انتقالی، $X = [1, x_1, \dots, x_r]$ ماتریس بردارهای ورودی به شبکه، β ماتریس وزن‌های ارتباطی بین لایه میانی و لایه خروجی، γ ماتریس وزن‌های ارتباطی بین لایه میانی و لایه ورودی هستند.

وایت (۱۹۸۹)، به منظور بررسی وجود ساختار غیرخطی، یک مدل شبکه عصبی پیشخور با یک لایه میانی را بر باقی‌مانده‌های حاصل از یک مدل خطی از سری زمانی برازش کرد. زیرا چنانچه ساختار اصلی سری زمانی خطی باشد، بین باقی‌مانده‌های حاصل از برازش مدل خطی و خروجی مدل شبکه مصنوعی نباید رابطه‌ای وجود داشته باشد.

1. Activation Function or Transfer Function.

Bias

Summi
junctio

در این آزمون فرض صفر عبارت است از $E(e_t G_t) = 0$ که e_t باقی‌مانده حاصل از مدل خطی و G_t بردار خروجی تابع انتقالی غیر خطی در لایه میانی شبکه عصبی است. آماره این آزمون به صورت رابطه $\chi^2(q) \rightarrow TR^2$ بیان می‌شود که T تعداد مشاهدات و R^2 مجذور ضریب همبستگی حاصل از رگرسیون خطی خطاهای مدل خطی ARMA روی سری زمانی قیمت نفت و مؤلفه‌های اصلی^۱ لایه خروجی شبکه عصبی و مشاهدات سری زمانی قیمت نفت است. (در مواردی که ابعاد بردار متغیرهای توضیحی بزرگ بوده و در عین حال، اجزای این بردار با یکدیگر همبستگی داشته باشند، می‌توان با استفاده از روش تحلیل مؤلفه‌های اصلی از ابعاد این بردار کاست). نتایج آزمون شبکه عصبی در جدول (۷) آورده شده است.

جدول - ۷. نتایج آزمون شبکه عصبی برای بررسی ساختار غیرخطی قیمت نفت (۱۹۹۸-۲۰۰۳)

حد بحرانی (توزیع χ^2)	درجه آزادی	آزمون وایت	R-square
۱۱ / ۰۷ (۰ / ۰۵)	۵	۱۲ / ۶۵	۰ / ۱۹

همان‌طور که ارقام جدول نشان می‌دهند، فرض صفر آزمون که دلالت بر خطی بودن سری دارد در سطح ۵٪ رد می‌شود و این موضوع با نتایج حاصل از آزمون BDS سازگار است.

در قسمت بعد، با طراحی یک مدل شبکه عصبی مصنوعی به پیش‌بینی قیمت نفت که طبق آزمون‌های بالا دارای فرایند آشوبناک است می‌پردازیم و نتیجه آن را با سایر مدل‌ها مقایسه می‌کنیم.

۵. طراحی یک شبکه عصبی مصنوعی (ANN) برای پیش‌بینی قیمت نفت

طی سال‌های اخیر، شبکه‌های عصبی به عنوان رقیب قدرتمند مدل‌های غیرخطی برای پیش‌بینی سری‌های زمانی، مدل‌سازی و شبیه‌سازی مورد استفاده قرار گرفته‌اند. تا مدت‌ها مدل‌های خطی به عنوان تنها ابزار پیش‌بینی سری‌های زمانی مورد استفاده قرار می‌گرفتند. مدل‌های خطی با وجود برخی مزیت‌ها، با محدودیت‌هایی روبرو هستند؛ از جمله اینکه قادر به بیان روابط غیرخطی نیستند. مدل‌های غیرخطی نظیر مدل‌های ARCH، TAR، STAR نیز که تاکنون مورد استفاده قرار گرفته‌اند، اغلب برای حل یک مسئله خاص، مفید واقع می‌شوند، در حالی که در حل مسائل دیگر ممکن است ناموفق ظاهر شوند. از سوی دیگر، یک مدل غیرخطی خاص ممکن است به تنهایی قادر به حذف تمام الگوهای غیرخطی از داده‌ها نباشد. برخلاف روش‌های غیرخطی متداول، شبکه‌های عصبی قادر به حذف تمام ساختارهای غیرخطی داده‌ها هستند (Wu, 1995 و Zhang, 2001).

1. Principal Component.
2. Artificial Neural Network.

پژوهشگران از توانایی‌های شبکه‌های عصبی، برای پیش‌بینی سری‌های زمانی استفاده می‌کنند. معصومی، ختن‌زاد و عبایی (۱۹۹۴) با استفاده از الگوریتم "پس‌انتشار خطا" برخی سری‌های زمانی اقتصاد کلان آمریکا مانند نرخ اشتغال و شاخص قیمت مصرف کننده را پیش‌بینی کرده‌اند. مشیری و کامرون (۲۰۰۰) به پیش‌بینی تورم کانادا با استفاده از شبکه‌های عصبی پرداخته‌اند. در مقاله دیگر، مشیری (۱۳۸۰) از یک مدل شبکه عصبی با الگوریتم یادگیری LM برای پیش‌بینی تورم ایران استفاده و نتیجه را با مدل‌های ساختاری و خودرگرسیون مقایسه می‌نماید. سوانسون و وایت (Swanson & White 1995) از شبکه‌های عصبی برای پیش‌بینی مقادیر آتی ۹ متغیر اقتصادی استفاده نموده‌اند. داربلی و اسلما (Darbellay & Slama 2000) از شبکه‌های عصبی برای پیش‌بینی تقاضا برای انرژی الکتریکی استفاده و نتیجه آن با پیش‌بینی مدل خطی ARMA مقایسه می‌نمایند. ژانگ (Zhang, 1999) از شبکه‌های عصبی برای پیش‌بینی ۸ سری زمانی با ساختار غیرخطی استفاده کرده است. پژوهش دیگری را وو (Wu, 1995) به منظور بررسی عملکرد شبکه‌های عصبی در پیش‌بینی نرخ ارز انجام داده است. از پژوهش‌های دیگر می‌توان از Moody, Indro, 1998, Tal & Nazareth, 1995, 1995, McMenamin, Monforte, 1998 نام برد.

برای پیش‌بینی، شبکه فضای ورودی (مقادیر جاری و گذشته سری زمانی و یا سایر متغیرهای توضیحی) را به فضای خروجی (مقادیر پیش‌بینی) می‌نگارد. برای ایجاد الگوهای ورودی^۱ از سری زمانی اصلی، پنجره‌ای با طول ثابت از روی سری زمانی عبور داده می‌شود (Zhang et.al, 2001). خروجی یک شبکه عصبی که برای پیش‌بینی یک سری زمانی از آن استفاده می‌شود را می‌توان به شکل زیر

$$\hat{P}_t = f(P_{t-1}, P_{t-2}, \dots, P_{t-l}) \quad \text{نشان داد:}$$

به طوری که: \hat{P}_t مقدار پیش‌بینی متغیر در زمان t ، l بُعد بردار ورودی یا تعداد وقفه‌هایی است که در مدل وارد شده و f تابعی است غیرخطی. می‌توان رابطه فوق را به شکل:

$$\hat{P}_t = b_0 + \sum_{i=1}^q w_i \tanh(b_{i0} + \sum_{j \geq 1} w_{ij} P_{t-j})$$

بیان داشت. در این رابطه، b_0 عدد ثابت (برابر با یک) در لایه میانی، b_{i0} عدد ثابت لایه ورودی، w_i وزن های ارتباطی بین لایه میانی و لایه خروجی و w_{ij} وزن های ارتباطی لایه ورودی و لایه میانی‌اند.

در این مطالعه، ابتدا سری زمانی به دو گروه آموزش^۲ (داده‌های داخل نمونه از ۴ آوریل ۱۹۸۳ تا ۲۵ ژوئن ۲۰۰۰) و گروه آزمون^۳ (داده‌های خارج از نمونه از ۲۶ ژوئن ۲۰۰۰ تا ۱۳ ژانویه ۲۰۰۳) تقسیم

1. Input Pattern.
2. Training Set.
3. Test Set.

می‌شود. از داده‌های گروه آموزش جهت طراحی شبکه و از گروه آزمون برای اندازه‌گیری میزان موفقیت پیش‌بینی مدل استفاده می‌شود.

ساختار شبکه مورد استفاده عبارت است از یک شبکه پیشخور^۱ سه لایه (یک لایه ورودی، یک لایه میانی با ۵ نورون و یک لایه خروجی) با تابع فعال ساز غیرخطی "تانژانت هیپربولیک" در لایه میانی و تابع "خطی" در لایه خروجی و الگوریتم یادگیری "پس انتشار خطا". به منظور پیش‌بینی قیمت نفت، وقفه اول سری به عنوان ورودی شبکه و خود سری به عنوان خروجی مطلوب در نظر گرفته شده‌اند. ضمناً پیش‌بینی به صورت پیش‌بینی پویا (دینامیک) انجام شده است، به طوری که برای پیش‌بینی قیمت نفت در هر زمان، از مقدار پیش‌بینی شده قبلی، و نه مقدار تحقق یافته، آن استفاده می‌شود. به کمک چنین ساختاری مقادیر آتی قیمت نفت برای یک دوره زمانی ۷۰۰ روزه متعلق به "گروه آزمون" (۲۶ ژوئن ۲۰۰۰ تا ۱۳ ژانویه ۲۰۰۳) پیش‌بینی و نتیجه به دست آمده با پیش‌بینی مدل‌های ARMA و GARCH که در قسمت‌های قبلی تصریح شدند، مقایسه شده است (نمودارهای (۳-الف تا ۳-ج)). به منظور ارزیابی میزان موفقیت پیش‌بینی از معیارهای MAE^۲ و RMSE^۳ که طبق روابط زیر تعریف می‌شوند، استفاده شده است:

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

$$MAE = \frac{\sum |y_t - \hat{y}_t|}{n}$$

جدول ۸ - مقایسه عملکرد مدل شبکه عصبی (ANN) با مدل‌های ARMA و GARCH

در پیش‌بینی قیمت نفت

Diebold statistic	MAE	RMSE	مدل
-۸/۱۱	۴/۸۱	۵/۴۱	ARMA
۷/۱۳	۲/۹۰	۳/۹۰	GARCH
-	۲/۰۴	۲/۸۵	ANN

1. Feedforwad.
2. Mean Absolute Error.
3. Root Mean Square Error.

همان‌طور که جدول (۸) نشان می‌دهد، مدل ANN نسبت به مدل‌های ARMA و GARCH از قدرت پیش‌بینی بهتری برخوردار است. به منظور بررسی معنی داری اختلاف بین نتایج حاصل پیش‌بینی مدل شبکه عصبی با مدل‌های رقیب، از آماره دیبولد-ماریانو^۱ به شرح زیر استفاده می‌شود:

$$s = \frac{\bar{d}}{\sqrt{\hat{\phi}}}$$

که در آن:

$$\bar{d} = \frac{1}{T_f} \sum_{t=1}^{T_f} d_t$$

$$\hat{\phi} = \frac{1}{t} \left(\hat{\gamma}_0 + 2 \sum_{i=1}^{k-1} \hat{\gamma}_i \right) \quad \text{و}$$


در اینجا $\hat{\phi}$ واریانس مجانبی، k افق پیش‌بینی (در اینجا یک)، $\hat{\gamma}_i$ تخمین i -ام اتوکوواریانس و $\hat{\gamma}_0$ تخمین واریانس است. همچنین، عبارت d_t از تفاضل خطاهای پیش‌بینی مدل ANN با مدل‌های ARMA و GARCH و به صورت زیر محاسبه می‌شود:

$$d_t = (y_t - \hat{y}_{tm_1})^2 - (y_t - \hat{y}_{tm_2})^2 \quad t = 1, 2, \dots, T_f$$

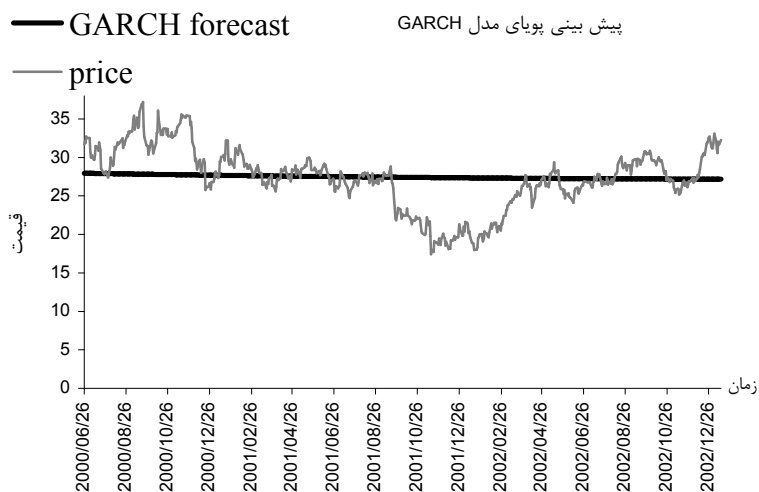
آماره دیبولد-ماریانو برای نمونه‌های بزرگ دارای توزیع نرمال با میانگین صفر و واریانس یک است. با توجه به اینکه مقدار محاسبه شده این آماره بیش از مقدار بحرانی در جدول توزیع نرمال است، فرض صفر برابری آماری نتیجه پیش‌بینی دو مدل آلترناتیو ARMA و GARCH با مدل شبکه عصبی (ANN) رد می‌شود. بنابراین می‌توان گفت که مدل شبکه عصبی نسبت به مدل‌های ARMA و GARCH از قدرت پیش‌بینی بهتری برخوردار است.

1. Diebold-Mariano.

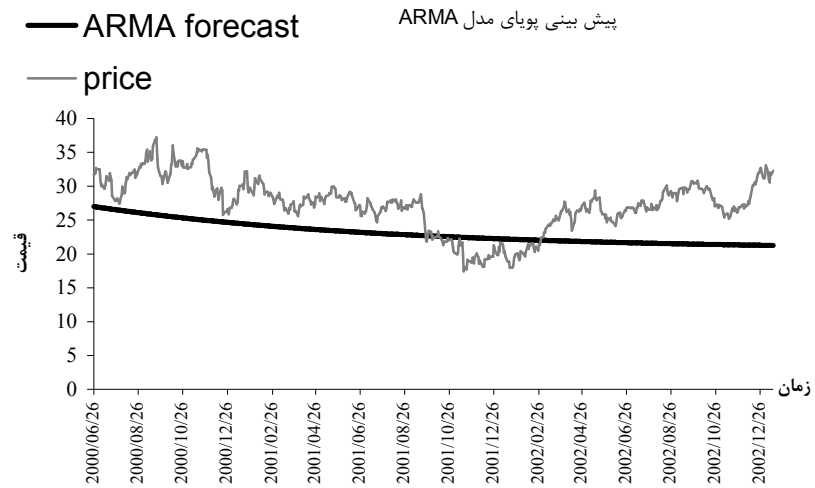
نمودار ۳- الف. (برای دوره زمانی از ژوئن ۲۰۰۰ تا ژانویه ۲۰۰۳)



نمودار ۳- ب. پیش‌بینی پویای مدل GARCH برای دوره زمانی از ژوئن ۲۰۰۰ تا ژانویه ۲۰۰۳



نمودار ۳- ج. پیش‌بینی پویای مدل ARMA برای دوره زمانی ژوئن ۲۰۰۰ تا ژانویه ۲۰۰۳



نتیجه‌گیری

به دلیل وجود نوسانات بسیار زیاد و پیچیده، اغلب فرایند مولد سری زمانی قیمت نفت خام به صورت فرایندی تصادفی در نظر گرفته می‌شود. نظریه آشوب، در پی جستجوی نظم در رفتار به ظاهر تصادفی سیستم‌های دینامیک غیرخطی معین است. نظریه آشوب در بازارهای مالی دلالت بر این دارد که قیمت در این بازارها به طور کامل از یک رابطه معین غیرخطی پیروی کرده و در صورت آگاهی دقیق از شرایط آغازین، قابل پیش‌بینی خواهد بود. در این پژوهش، آزمون‌های آشوب برای سری زمانی روزانه قیمت نفت شاخص WTI در بازار مبادلات کالاهای نیویورک (NYMEX)، در یک دوره زمانی ۲۰ ساله را انجام داده‌ایم سؤال اصلی این است که آیا دلیل نوسانات قیمت نفت خام در این بازار، مکانیزم درونی سیستم مولد آن است و یا تکانه‌های خارجی و تصادفی به ایجاد چنین رفتارهای به ظاهر بی نظم منجر شده است؟

در این مقاله، جهت بررسی آشوبناک بودن فرایند مولد قیمت نفت از برخی آزمون‌ها استفاده شد. آزمون‌های معرفی شده هر یک محدودیت‌ها و مزایای خاص خود را دارند، بنابراین با انجام کلیه آنها می‌توان ایده بهتری نسبت به شرایط حاکم بر داده پیدا کرد. ابتدا، از آزمون‌های نمای لیاپانوف و بعد همبستگی به عنوان آزمون مستقیم کشف آشوب استفاده شد که هر دو مورد به شواهدی مبنی بر وجود آشوب در سری زمانی تأکید داشتند. آزمون BDS و شبکه عصبی نیز بر وجود ساختار غیرخطی دلالت داشتند. بنابراین، آزمون‌های مورد استفاده در این پژوهش وجود آشوب در سیستم مولد داده‌ها را تأیید کرده‌اند.

با توجه به آزمون BDS و شبکه عصبی در این مطالعه، می‌توان نتیجه گرفت که به دلیل غیرخطی بودن سیستم مولد قیمت نفت بازار معاملات کالای نیویورک، استفاده از مدل‌های خطی برای برآورد و پیش‌بینی قیمت نفت دقیق نخواهد بود و انتظار می‌رود که مدل‌های غیرخطی دقیق‌تر عمل نمایند. از سوی دیگر، مدل‌های شبکه عصبی مصنوعی با توجه به اینکه ساختاری غیرخطی و انعطاف پذیر دارند، قادرند هر نوع الگوی حاکم بر داده‌ها را فرا گرفته، برآورد و پیش‌بینی دقیقی از آنها ارائه کنند. در این مطالعه با استفاده از یک شبکه عصبی پیش‌خور سه لایه با تابع فعال ساز غیرخطی "تانژانت هیپربولیک" در لایه میانی و تابع خطی در لایه خروجی و الگوریتم یادگیری "پس انتشار خطا"، مقادیر آتی قیمت نفت برای یک دوره زمانی ۷۰۰ روزه (از ژوئن ۲۰۰۰ تا ژانویه ۲۰۰۳) پیش‌بینی و نتیجه با مدل خطی ARMA و غیرخطی GARCH مقایسه شد. نتایج به دست آمده نشان داد که برای پیش‌بینی دینامیک (پویا) سری زمانی قیمت نفت شاخص WTI در بازار آمریکا، مدل ANN از قدرت پیش‌بینی بهتری نسبت به مدل‌های ARMA و GAECH برخوردار است.

منابع

- ابریشمی، حمید، معینی، علی و احراری، مهدی. (۱۳۸۱). آزمون ناخطی معین برای قیمت‌های نفت، فصلنامه پژوهش‌های اقتصادی ایران، شماره ۱۰، بهار.
- اصغری اسکویی، محمد رضا. (۱۳۸۱). کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های زمانی. فصلنامه پژوهش‌های اقتصادی ایران. شماره ۱۲، پاییز.
- مشیری، سعید. (۱۳۸۰). پیش‌بینی تورم ایران با استفاده از مدل ساختاری، سری‌های زمانی و شبکه‌های عصبی. مجله تحقیقات اقتصادی، شماره ۵۸، بهار و تابستان.
- مشیری، سعید. (۱۳۸۱). مروری بر نظریه آشوب و کاربردهای آن در اقتصاد. فصلنامه پژوهش‌های اقتصادی ایران، شماره ۱۲، پاییز.
- Abosedra, S., Laopodis, N. (1997). Stochastic Behavior of Crude Oil Prices: A GARCH Investigation. *The Journal of Energy and Development* 21, No.2.
- Adrangi, B., Chatrath, C., (2001). Chaos in Oil Prices? Evidence from Futures Market. *Energy Economics*, 23, PP. 405-425.
- Barnett, W, A. et al. (1997). A Single-Blind Controlled Competition Among Tests for Nonlinearity and Chaos. *Journal of Econometrics*, 82, PP. 157-192
- Bacon, Robert. (1991). Modelling the Price of Oil. *Oxford Review of Economic Policy*, Vol. 7, No.2, Summer.
- Brock, W. (1988). Is the Business Cycle Characterized by Deterministic Chaos? *Journal of Monetary Economics*, 22, PP.71-90.
- Brock, W. Hsieh, D. Lebaron, B. (1993). Nonlinear Dynamics, Chaos and Instability, Statistical Theory and Economic Evidence, The MIT Press.
- Chatfield, C. (2000). *Time Series Forecasting*. Chapman&Hall /CRC.
- Chatrath, A., Adrangi, B., Dhanda, K. (2002). Are Commodity Prices Chaotic? *Agricultural Economics*, 27, PP.123-137.
- Darbellay, Georges A, Slama, Marek. (2000). Forecasting the Short Term Demend for Electricity Do Neural Networks Stand a Better Chance? *International Journal of Forecasting*, 16, PP.71-83.
- Diebold, F.X. and Mariano, R.S. (1995). Comparing Predictive Accuracy. *Journal of Business and economic Statistics*, 13, PP.253-263.
- Eckmann, J.P., Ruelle, D. (1992). Fundamental Limitations for Estimating Dimensions and Lyapunov Exponents in Dynamical Syatems. *Physica D*. S6, PP.185-187.
- Frank, M., Stengos, T. (1988). Some Evidence Concerning Macroeconomic Chaos. *Journal of Monetary Economics*, 22, PP.423-438.
- Gilmore, C.G. (2001). An Examination of Nonlinear Dependence in

- Exchange Rates, Using Recent Methods from Chaos Theory. *Global Finance Journal*, 12, PP.139-151.
- Harrison, Robert G., et al. (1999). Non-linear Noise Reduction and Detecting Chaos: Some Evidence from the S&P Price Index. *Mathematics and Computer in Simulation*, 48, PP. 497-502.
- Haykin, Simon. (1999). *Neural Networks, A Comprehensive Foundation*. Second Edition, Printice Hall International Inc.
- Hsieh, D. (1989). Chaos and Nonlinear Dynamics: Application to Financial Markets. *The Journal of Finance*, Vol. XLVI, No.5
- Hsieh, D. (1989). Testing for Nonlinear Dependence in Daily Foreign Exchange Rates, *Journal of Bussiness*, 62, PP. 339-368.
- Indro, D.C., Jiang, C.X., Patuwo, B.E., Zhang, G.P. (1999). Predicting Mutual Fund Performance Using Artificial Neural Networks. *Omega, Int. J. Mgmt. Sei.* 27 PP. 373-380.
- Kuan, C., and H. White. (1994). Artificial Neural Networks: An Econometrics Perspective, *Econometric Review*, 13, Nov.
- McMenamin, S. Monforte, F. (1998). Short Term Energy Forecasting with Neural Networks, *The Energy Journal*, Vol. 19. No.4.
- Medio A. (1992). *Chaotic Dynamics, Theory and Application to Economics* Cambridge University Press.
- Moody, John. (1995). Economic Forecasting: Challenges and Neural Network Solutions, Keynote, *Talk Presented at the Symposium on Artificial Neural Networks*, Hsinchu, Taiwan, December.
- Moshiri, S. Brown, L. Unemployment Variation over Business Cycles: a Comparison of Forecasting Models. *Journal of Forecasting*, forthcoming.
- Moshiri, S., Cameron, N., and Scuse, D. (1999). Static, Dynamic and Hybrid Neural Networks in Forecasting Inflation. *Computational Economics*, 14, PP.219-235.
- Moshiri, S., Cameron, N. (2000). Neural Network Versus Econometric Models in Forecasting Inflation, *Journal of Forecasting*, 19, PP.201-217.
- Moshiri, S., Kohzadi, N., and Cameron, N. (2002). Testing for Stochastic Nonlinearity in the Rational Expectations Permanent Income Hypothesis. *Iranian Economic Review*, 6.
- Panas, E., Ninni, V. (2000). Are Oil Markets Chaotic? A Nonlinear Dynamic Analysis. *Energy Economics*, 22 PP.549-568.
- Perron, P. (1989). The Great Crash, the Oil Price Shocks and Unit Root Hypothesis. *Econometrica*, 57, PP.1361-1401.
- Pindyck, Robert S. (1999). The Long- Run Evolution of Energy Prices, *The Energy Journal*, Vol. 20, No.2.
- Swanson, Norman R., and White, Helbert. (1995). A Model Selection

-
- Approach to Real-Time Macroeconomic Forecasting Using Linear Models and Artificial Neural Networks, Discussion Paper, Department of Economics. Pennsylvania State University.
- Tal, Benny, Nazareth, Linda. Artificial Intelligence and Economic Forecasting, Economic Division, Canadian Imperial Bank of Commerce
- Wolf, A. Swift, J., Swinney, H., Vastando, J. (1985). Determining Lyapunov Exponent from a Time Series. *Physica*, 16 D PP.285-317.
- Wu, Berlin. (1995). Model-free Forecasting for Nonlinear Time Series (With Application to Exchange Rates). *Computational Statistics & Data Analysis*. North Holland, 19, PP.433-459
- Zhang, G. Peter, Patuwo, B. Eddy, Hu, Michael Y. (2001). A Simulation Study of Artificial Neural Networks for Nonlinear Time- Series Forecasting. *Computers & Operations Research*, 28 381-396.