



مقایسه عملکرد مدل‌های رگرسیونی ARIMA و شبکه عصبی بالگوریتم ژنتیک (GMDH) در پیش بینی قیمت نفت خام ایران

عباسعلی ابونوری^۱

ناهید خدادادی^۲

تاریخ پذیرش: ۹۱/۵/۲۰

تاریخ دریافت: ۹۱/۳/۱۲

چکیده

این پژوهش باهدف معرفی یک الگوی مناسب جهت پیش بینی قیمت نفت خام سنگین ایران صورت پذیرفته است. داده های مورد استفاده در این پژوهش به صورت هفتگی و شامل بازه ی زمانی هفته سوم ۲۰۰۲/۴ الی هفته چهارم ۲۰۱۱/۷ که مشتمل بر ۴۸۵ مشاهده بوده که جهت مجزاسازی پیش بینی های داخل نمونه ای و خارج از نمونه استفاده شده است. همچنین الگوهای مورد استفاده در این پژوهش عبارتند از: یک مدل شبکه عصبی مصنوعی مبتنی بر الگوریتم ژنتیک (GMDH) و نیز یک مدل رگرسیونی خطی (ARIMA) یافته های این پژوهش نشان می دهد که مدل شبکه عصبی مبتنی بر الگوریتم در پیش بینی های خارج از نمونه بر اساس معیارهای محاسبه خطای پیش بینی میانگین مجذور خطا (MSE) و نیز معیار جذر میانگین مجذور خطا (RMSE) دارای عملکرد بهتری نسبت به مدل رگرسیونی خطی ARIMA می باشد.

واژه‌های کلیدی: پیش بینی قیمت نفت خام ایران مدل ARIMA مدل شبکه عصبی مصنوعی.

۱- استادیار دانشکده اقتصاد و حسابداری دانشگاه آزاد اسلامی واحد تهران مرکزی aabounoori@yahoo.com

۲- دانشجوی کارشناسی ارشد علوم اقتصادی دانشکده اقتصاد و حسابداری تهران khodadadina@gmail.com

۱- مقدمه

بازارنفت یکی از بازارهای پرتلاطم است که پیش بینی آینده آن می تواند در تصمیم گیریها تأثیر مثبتی بر جای بگذارد. هرچند وقوع بحرانهای نفتی که ناگهان در بازارنفت حادث می شوند، درجه اطمینان بسیاری از این پیش بینی هارا با تردید مواجه می سازند. با آگاهی از قیمت نفت و پیش بینی صحیح آن می توان فرایند تصمیم گیری خرید و فروش نفت در بازار جهانی را تسهیل و بهترین زمان انجام معاملات و سرمایه گذاریها را تعیین نمود. (اصفهانیان و امین ناصری، ۱۳۸۷) مسیر تغییرات قیمت نفت نیز همچون قیمت دیگر دارایی ها، تحت فرضیه ی بازارهای کارآمد، نوعی فرایند گام تصادفی است و به همین دلیل بهترین پیش بینی آن، قیمت دوره ی (روز) گذشته آن خواهد بود. به همین دلیل ارائه الگوهایی برای پیش بینی شاخص های عمده بازارنفت همواره مورد توجه پژوهشگران بوده است.

از این رو با توجه به اهمیت موضوع مسئله پیش بینی متغیرهای اقتصادی مدل های مختلفی برای مدلسازی روابط بین متغیرها و پیش بینی آنها بوجود آمده اند. این مدل هارا از چند جهت می توان تقسیم بندی نمود: مدل های سری زمانی و ساختاری یا مدل های خطی و غیر خطی. اهمیت روزافزون پیش بینی برای عوامل اقتصادی از یک سو و کاستی مدل های ساختاری در پیش بینی از سوی دیگر منجر به توسعه مدل های سری زمانی برای مدلسازی پیش بینی شد. در مدل های سری زمانی فرض می شود تمامی عوامل و ارتباطات مؤثر در شکل گیری یک متغیر در مقادیر خود آن نمود پیدا می کنند، بنابراین از مقادیر قبلی خود متغیر می توان به عنوان مهم ترین منبع توضیح تغییرات یک متغیر استفاده نمود و پیش بینی را تنها بر اساس اطلاعات قبلی خود متغیر انجام داد. بر طبق این دیدگاه اگر بتوان فرایند مولد یک متغیر را بدست آورد پیش بینی آن متغیر نسبتاً به راحتی امکان پذیر خواهد بود. اما از آنجا که در مدل های سری زمانی سهم نسبی سایر عوامل مؤثر در تغییرات متغیر وابسته مشخص نیست آنها از کاربرد کمتری در سیاست گذاری برخوردارند. باید توجه داشت هنگامی نتایج پیش بینی مدل های سری زمانی از اعتبار کافی برخوردارند که بتوان فرایند مولد مقادیر یک متغیر را به خوبی بدست آورد. (مشیری و فروتن، ۱۳۸۳)

اخیراً پژوهشگران، در مقابل مدل های رگرسیونی در مطالعات اقتصادی خود از روش شناسی شبکه عصبی، که مبتنی بر شبیه سازی های کامپیوتری با استفاده از نرون های عصبی هستند و به کمک یک تابع پایه ای ریاضیاتی اعمال خود را انجام می دهند، (فرجام

نیا، ۱۳۸۴) بهره می‌جویند. چراکه مدل‌های شبکه عصبی، هنگامی که میان داده‌های ورودی و خروجی ارتباط غیرخطی وجود دارد، به راحتی با سیستم آموزش ریاضی خود به تخمین و پیش‌بینی متغیر وابسته می‌پردازد به گونه‌ای که خطای برآورد و پیش‌بینی این مدل هابسیار کوچک می‌باشد.

هدف این پژوهش مقایسه عملکرد مدل‌های سری زمانی خطی (ARIMA) و شبکه‌ی عصبی بالگوریتم (GMDH) در پیش‌بینی قیمت نفت خام سنگین ایران بوده و فرضیه‌ی اصلی این مطالعه، برتری مدل شبکه‌ی عصبی بالگوریتم (GMDH) نسبت به مدل سری زمانی خطی (ARIMA) در پیش‌بینی سری مذکور می‌باشد.

۲- مبانی نظری و پیشینه تحقیق

۲-۱- بررسی روند تاریخی قیمت نفت

اگرچه بررسی قیمت نفت خام تا پیش از قرن ۲۱ در بازه‌ی زمانی این مطالعه قرار ندارد، ولی رصد نمودن وقایع مؤثر بر قیمت این محصول در این دوره نیز می‌تواند دید وسیع‌تری را جهت بررسی و مقایسه مجموعه عوامل اثرگذار بر قیمت نفت خام در اختیار محقق قرار دهد. به طور کلی روند قیمت نفت در طول زمان بانوسانهای زیادی همراه بوده است و شدت این نوسانات در دوره‌های مختلف متفاوت بوده است. مهمترین حوادث طی سالهای ۱۹۷۲-۲۰۰۶ از قرار زیر می‌باشند (دلآوری و باغبان زاده، ۱۳۸۶):

۱) تحریم نفتی اعراب (۱۹۷۳-۷۴)

۲) انقلاب ایران (۱۹۷۸-۷۹)

۳) حمله عراق به ایران (۱۹۷۹-۸۰)

۴) افزایش تولید عربستان و ابداع روش جدید موسوم به نت بک (۱۹۸۵-۸۶)

۵) تهاجم عراق به کویت (۱۹۸۹-۹۰)

۶) بحران مالی جنوب آسیا (۱۹۹۷-۹۸)

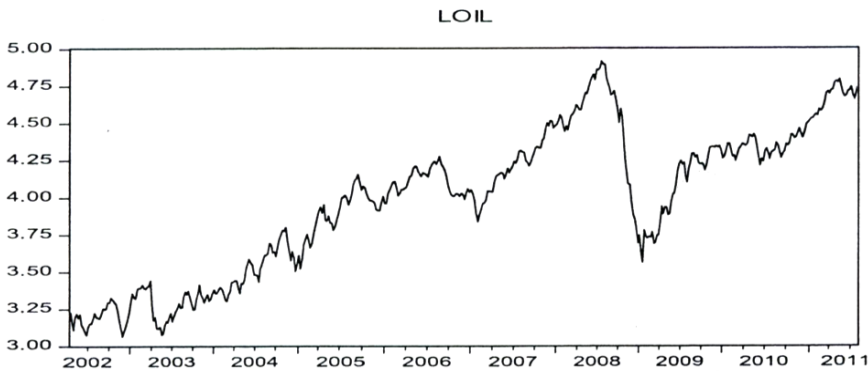
۷) حادثه یازدهم سپتامبر (۱۹۷۳-۷۴)

۸) اشغال عراق (۲۰۰۳-۰۴)

۹) مسائل ژئوپلیتیک و عوامل سیاسی (۲۰۰۶-۰۷)

پس از وقوع حادثه ۱۱ سپتامبر ۲۰۰۱ که قیمت‌های نفت اندکی کاهش یافت، تأثیرپذیری قیمت‌های نفت از عوامل خارجی وارد مرحله جدیدی شد بطوریکه نقش اساسی عوامل بازار بر قیمت‌ها به حد قابل رسید و تا سالهای بعد از آن یعنی ۲۰۰۲ و ۲۰۰۳ این

مسائل سیاسی بود که نقش اساسی در شکل گیری قیمت هدا داشت و می توان اعتصابات کارکنان صنایع نفت درونزوتلا، خروج برخی شرکتهای نفتی از نیجریه و حمله آمریکا به عراق و در نتیجه قطع کامل صادرات این کشور از جمله حوادث پیش بینی نشده این سالها نام برد به طوریکه این برهه را می توان یک دوره استثنائی در تاریخ بازار نفت قلمداد کرد (امامی میبیدی، ۱۳۸۵).



منبع: یافته های محقق

نمودار (۱): روند تاریخی قیمت نفت خام سنگین ایران

در سال ۲۰۰۸ با وقوع بحران مالی در آمریکا و سرایت آن به اقتصاد جهانی، شاهد کاهش چشمگیری در قیمت نفت بودیم به طوری که قیمت آن از حدود ۱۵۰ دلاری به حدود ۳۵ دلار در هر بشکه رسید. در سال ۲۰۰۹ متوسط قیمت نفت به ۶۰ دلار می رسد و در سالهای ۲۰۱۰ و ۲۰۱۱ میلادی افزایش قیمت نفت و عدم افزایش تولید ناخالص دنیامتناسب با قیمت نفت سبب شده تا شاخص هزینه نفت در سطوحی بالاتر از سال ۲۰۰۸ قرار گیرد. نمودار (۱) تحولات قیمت نفت را از سال ۲۰۰۲ تا ۲۰۱۱ به خوبی نشان می دهد.

۲-۲- مطالعات پیشین

تغییرات قیمت انرژی به عنوان یک نهاد استراتژیک در فرایند تولید، اثرات قابل توجهی بر اقتصاد هر کشور دارد. نقش و کاربردهای نفت از میان سایر انرژی ها برهیچ کس پوشیده نیست (دشتی رحمتی و همکاران، ۱۳۸۹). نه تنها تغییرات قیمت انرژی و به خصوص نفت

خام در تمامی کشورها حائز اهمیت، بلکه این اهمیت در ایران دو چندان می باشد. چراکه بخش اعظم تولید ناخالص داخلی ایران از کانال درآمدهای نفتی بوده، بنابراین تغییرات قیمت نفت در این کشور از اهمیت بالایی برخوردار می باشد. دلایل ذکر شده، مطالعات فراوانی در زمینه ی نوسانات و تغییرات قیمت نفت صورت پذیرفته است. از جمله ی آنان می توان به موارد زیر اشاره نمود:

پرادو^۱ (۲۰۱۱) به بررسی حافظه بلندمدت در بازار نفت پرداخته است. ایشان بیان می کند که پدیده حافظه بلندمدت بازار نفت به سهولت از روش کاتسومی شیموتسو^۲ قابل تعیین است. همچنین نشان می دهد وجود حافظه بلندمدت، عدم کارایی های بازار نفت را نشان می دهد. مصطفایی و سخابخش (۲۰۱۱) در مقاله ای به مدل سازی و پیش بینی قیمت نفت اوپک در قالب معروفترین مدل میتنی بر حافظه بلندمدت پرداختند. آنها برای این منظور از داده های روزانه قیمت نفت اوپک از ۳ ژانویه ۱۹۹۷ الی ۱۱ ژوئن ۲۰۱۰ استفاده نمودند. ضریب تفاضل گیری کسری محاسبه شده در این پژوهش برابر (۰/۳۴) بوده که مزید حافظه بلندمدت نیز می باشد نتایج این تحقیق نشان می دهد که مدل ARFIMA نسبت به مدل های ARIMA و ARMA بهتر پیش بینی می کند.

چوی و حموده^۳ (۲۰۰۹) به بررسی حافظه بلند مدت بازار نفت و محصولات تصفیه شده آن با مدل ARFIMA پرداخته اند. آنها نشان دادند که مدل های غیر خطی ARFIMA قیمت نفت را بهتر مدل سازی میکنند و همچنین این مدل در تداوم بازده قیمت نفت به مقدار جزئی شکست ساختار ی راکاهش می دهد. چیونگ^۴ (۲۰۰۹) با استفاده از مدل های مختلف ARCH به مدل سازی و پیش بینی قیمت نفت خام برنت و وست-تگزاس پرداخت. در این پژوهش ویژگی های دوسری زمانی مذکور اعم از تغییرات خوشه ای، اثرات اهرمی و حافظه بلندمدت با انواع مختلف مدل های ARCH مورد بررسی قرار گرفت. نتایج این مطالعات نشان داده اند که ویژگی حافظه بلندمدت در نفت خام وست-تگزاس برجسته تر از همین ویژگی در نفت برنت خام بوده و همچنین مدل تجربی نفت خام وست-تگزاس مدلی نامتقارن بوده است. در نهایت نیز پیش بینی نفت خام برنت در دوره خارج از نمونه کاراتر و دقیق تر از پیش بینی قیمت نفت خام وست-تگزاس می باشد.

تسی^۵ (۲۰۰۸) به تجزیه و تحلیل تورم با استفاده از مدل مارکوف سویچینگ - ARFIMA پرداخت و به این نتیجه دست یافت که، شک های ناگهانی قیمت نفت مسیر تغییرات نرخ بهره را شکل دهی میکند. همچنین نیز بیان می کند که نرخ بهره آمریکا دارای حافظه بلندمدت می باشد.

دشتی رحمت آبادی وهمکاران (۱۳۹۰) عملکردالگوهای شبکه عصبی و خود رگرسیون میانیگین متحرک رادر پیش بینی قیمت نفت خام ایران مورد ارزیابی قرار دادند. داده های به کارگرفته شده دراین پژوهش، هفتگی بوده و در دوره ی ۱۹۹۷-۲۰۱۰ جهت پیش بینی ۲۰۱۰ و ۳۰ درصد این داده ها و چهار الگوی شبکه عصبی و یک الگوی خودرگرسیون میانیگین متحرک استفاده شده اند. نتایج این تحقیق نشان می دهد که جهت پیش بینی ۱۰ درصدی داده های قیمت نفت خام الگوهای شبکه عصبی رگرسیون تعمیم یافته و آبخاری پس انتشارخطا باتابع آموزش شبه نیوتنی به ترتیب با خطایی کمتر از ۱ و ۲ درصد دارای بهترین عملکرد بوده جهت پیش بینی ۲۰ درصدی داده های قیمت نفت خام شبکه عصبی پیشخور پس انتشارخطا و المان پس انتشارخطا با انتشار آموزش لونیبرگ-مارکوآت، دارای عملکرد می باشند وهمچنین در مورد پیش بینی ۳۰ درصد این داده هانیز شبکه ی عصبی پیشخور پس انتشارخطا مطلوبتر ارزیابی شده اند. از جمله نتایج دیگر این مطالعه این بوده است که به طور نسبی با افزایش درصد داده های مورد استفاده در پیش بینی، دقت پیش بینی کاهش یافته وهمچنین در تمامی موارد دقت پیش بینی مدل های خودرگرسیون میانیگین متحرک از مدل های شبکه ی عصبی کمتر ارزیابی شده است. مهرآرا وهمکاران (۱۳۸۹) در مقاله ای به پیش بینی بی ثباتی قیمت نفت خام برنت و وست تگزاس اینترمدیت با استفاده از شبکه ی عصبی GMDH طی دوره زمانی اواخر سال ۱۹۹۰ تا اوایل سال ۲۰۱۰ (با استفاده از داده های روزانه) پرداختند. مقایسه نتایج حاصل از مدل های $GARCH(1,1)$ الگوی مبتنی بر شبکه ی عصبی GMDH الگوی ترکیبی GMDH و $GARCH$ نشان می دهد که الگوی ترکیبی و شبکه ی عصبی بر مبنای معیار جذر میانگین مربع خطای پیش بینی (RMSE) برای هر دوسری پیش بینی بهتری نسبت به الگوی اقتصادسنجی $GARCH(1,1)$ ارائه می دهند. وافی و عرفانی فرد در سال ۱۳۸۹ پیش بینی قیمت و درآمدهای نفت خام رادر سه حالت مورد بررسی قرار داده اند: ۱- زمانی که ورودی ها الگوی انتظارات تطبیقی است، ۲- وقتی ورودی ها قواعد تحلیلی فنی است و ۳- ترکیب موارد اول و دوم. نتایج این مقاله نشان می دهد که حالت سوم ضمن کاهش ریسک عایدی ها مقدار عاید تجمعی را نسبت به حالت اول و دوم به ترتیب ۷ درصد و ۱۰ درصد افزایش می دهد. همچنین به کارگیری انتظارات تطبیقی در کنار قواعد تحلیلی فنی مقادیر پیش بینی رادقیق ترمی کند. پورکاظمی و اسدی (۱۳۸۸) در مقاله خود با عنوان "پیش بینی پویایی نفت خام با استفاده از شبکه های عصبی مصنوعی و بابکارگیری ذخیره سازی های نفتی کشورمان

OECD^۶ به پیش بینی قیمت نفت خام به عنوان یکی از متغیرهای مهم بازار جهانی نفت، با استفاده از روش های شبکه های عصبی مصنوعی و نیز روش اقتصادسنجی ARIMA (به صورت پویا) پرداختند. از یکسو نتایج پیش بینی های یک گام به جلوتاده گام به جلو با استفاده از روش شبکه های عصبی در مقایسه با روش ARIMA حاکی از خطای کمتر روش شبکه های عصبی بوده و از سوی دیگر نتایج پیش بینی های شبکه عصبی نشان می دهد که با اضافه کردن ذخیره سازی های کشورهای OECD به عنوان یک ورودی دیگر در مدل و انجام یک پیش بینی دومتغیره (برای اولین بار در ایران)، خطای پیش بینی های قیمت نفت کاهش می یابد. شکیبایی و همکاران (۱۳۸۸) در مقاله ای به پیش بینی عرضه نفت خام در یازده کشور تولیدکننده با استفاده از شبکه های عصبی و رگرسیون خطی با توجه به داده های زمانی دوره ۱۹۸۰ الی ۲۰۰۶ پرداختند. نتایج به دست آمده در هر کشور را به طور مجزا مورد بررسی و مقایسه قرار دادند. نتیجه پژوهش آنها حاکی از عملکرد بهتر مدل های شبکه های عصبی نسبت به مدل های رگرسیون خطی در پیش بینی ها بوده است.

اصفهانیان و امین ناصری (۱۳۸۷) در مقاله خود با استفاده از یادگیری هدایت شده یک مدل شبکه عصبی مصنوعی را برای پیش بینی قیمت نفت خام به صورت ماهانه توسعه دادند. در فرایند توسعه این مدل تأثیر انواع متغیرهای فنی و بنیادی، تعداد نرون های لایه ورودی، تعداد نرون ها و لایه های پنهان، توابع تبدیل لایه ها پیش پردازش مناسب داده ها، تقسیمات مختلف داده ها برای انتخاب مجموعه های آموزش و آزمایش، انواع الگوریتم های یادگیری بهبود یافته و انواع شبکه ها با انجام آزمایشات فراوانی مورد بررسی قرار گرفته است. در نهایت یک شبکه پیش خورسه لایه میانگین خطای مطلق ۷۴ سنت در مجموعه آزمایش به عنوان بهترین مدل انتخاب گردیده است.

تحقیق دیگری که توسط مهرآرا و همکاران (۱۳۸۸) با رویکرد شبکه عصبی GMDH صورت پذیرفته است در زمینه الگو سازی و پیش بینی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران می باشد. این پژوهش سعی در شناخت متغیرهای مؤثر بر شاخص بورس اوراق بهادار داشته است و بازده متغیر کلان اقتصادی مرتبط با بازار سرمایه به همراه وقفه های یک و دو ماهه هر کدام از آنها و وقفه های متغیر وابسته، الگویی با ۳۵ متغیر ورودی را ایجاد کردند. نتایج به دست آمده نشان دهنده تأثیر قوی و معنادار شاخص قیمت زمین، هزینه مسکن، پایه پولی، کرایه، CPI، مسکن اجاره ای و قیمت جهانی نفت خام بر شاخص

قیمت وبازده نقدی بورس اوراق بهادار است. در مقابل، بازار ارز خارجی و طلا، ارتباط کمتری بابازار سهام داشته است.

کیانی در سال ۱۳۸۶، باتوجه به ضعف عملکرد مدل های سری زمانی سنتی در مواردی که پویایی سیستم، بیانگرویزگی غیرخطی قوی می باشد و نیز باتوجه به دقت بالای مدل های شبکه عصبی در اینگونه سیستم ها، در پایان نامه اش سعی در تخمین بهترین مدل پیش بینی سری زمانی برای تولید نفت خام نمود. لذا در ابتدا بهترین مدل ARMA را با توجه به معیارهای ارزیابی مدل، تخمین زده و سپس شبکه عصبی را وارد بحث کرده و در نهایت به مقایسه پیش بینی این مدل هاپرداخت. نتایج این پژوهش مرید عملکرد بهتر مدل های شبکه عصبی در پیش بینی های ایستا و پویا نسبت به مدل های ARMA می باشد.

فرجام نیا و همکاران (۱۳۸۶) در تحقیقی به مقایسه روشهای ARIMA و شبکه های عصبی مصنوعی در پیش بینی قیمت روزانه نفت خام طی دوره آوریل ۱۹۸۳ الی ژوئن ۲۰۰۵ پرداختند. آنها پس از مدل سازی بوسیله شبکه های عصبی مصنوعی، به منظور تشخیص سهم مشارکت هر پارامتر ورودی در این مدل از تجزیه و تحلیل حساسیت استفاده شده است. باتوجه به بکارگیری حجم وسیعی از اطلاعات روزانه قیمت جهانی نفت (بیش از ۵۵۰۰ داده) نتایج به دست آمده بیانگر برتری غیرقابل مقایسه مدل شبکه های عصبی مصنوعی نسبت به مدل ARIMA در پیش بینی قیمت روزانه نفت بوده است.

۳- معرفی مدل تحقیق و روش تحقیق

مدل های به کار گرفته شده در این تحقیق به دودسته ی: مدل سری زمانی (ARIMA) و مدل شبکه عصبی بالگوریتم ژنتیک (GMDH) تقسیم شده، که در بخش های بعدی به تفسیر آنها پرداخته خواهد شد.

۳-۱- فرایند یا الگوی خود توضیح میانگین متحرک (ARIMA):

بطور کلی فرآیند های ARMA از تلفیق فرآیندهای خود توضیح و میانگین متحرک بوجود می آیند. که به صورت زیر قابل نمایش می باشند:

$$\phi(L)y_t = \alpha + \theta(L)\varepsilon_t \quad (1)$$

که در این عبارت روابط زیر که به ترتیب در فرآیندهای AR و MA صدق می کردند، برقرار خواهد بود:

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p, \quad \varepsilon_t \approx iid(0, \sigma^2) \quad (2)$$

$$\theta(L) = 1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q, \quad \varepsilon_t \approx iid(0, \sigma^2) \quad (3)$$

$$\phi(L)(1-L)^d y_t = \alpha + \theta(L)\varepsilon_t \quad (4)$$

شرط مانایی این فرآیند همانند شرط مانایی در فرآیند خود توضیح می باشد. این فرایندها را خود توضیح میانگین متحرک با درجات آزادی p و q می نامند و به صورت $ARMA(p,q)$ نشان می دهند. حال اگر یک سری زمانی نامانا بوده و بتوان آنرا با d بارتفاضل گیری مانا کرد آنگاه می توان آن را به صورت زیر نمایش داد:

در این رابطه p تعداد جملات فرآیند خود توضیح و q تعداد جملات فرآیند میانگین متحرک و d تعداد دفعات لازم تفاضل گیری به منظور مانا شدن سری y_1 می باشند. این فرآیند را به صورت $ARMA(p,d,q)$ نشان می دهند. در این عبارت نیز روابط (۲) و (۳) که به ترتیب در فرآیندهای AR و MA یا به طور همزمان در فرآیند $ARMA$ صدق می کردند، برقرار می باشد.

۲-۳- شبکه عصبی الگوریتم ژنتیک (GMDH):

شبکه عصبی هوشمند مصنوعی نخستین بار در سال ۱۹۴۳ توسط مک کولا (عصب شناس) و پیت (ریاضی دان) بوجود آمد. از آنجا که مفاهیم پایه ای مطرح شده در مباحث مربوط به آن از اساس ریاضی مستحکم و قابل اعتمادی برخوردار بود، بعدها به طور گسترده ای مورد اقبال عمومی محققان در مدل سازی تجربی فرآیندهای غیر خطی قرار گرفت. نکته ی جالب توجه و دارای اهمیت در این مدل ها، شبیه سازی عملکرد پیچیده ی سلول های عصبی با تعداد زیاد واحد با عملکرد ساده و ارتباطات موازی می باشد.

یک مشکل اساسی در مدل سازی سیستم های پیچیده مانند مسائل اقتصادی اجتماعی و مسائلی که در مورد آنها فرآیند رفتاری و سازه داده ها نامشخص است، مسئله پیش داوری محقق در مورد ساختار مدل می باشد از آنجا که سیستم مورد نظر مسئله ممکن است پیچیده باشد فروض اولیه مدل ساز ممکن است در بهترین حالت تنها حدس های مبهمی باشد. بنابراین نتایج بدست آمده در این حالت مبهم دوپهلوی و اغلب کیفی دارند این مشکلات منجر به آن شد که در اواسط دهه ۱۹۶۰ ریاضی دان روسی ایواخنکو روشی را که تاحدی بر پایه نظریه روزنبلات^۷ ۱۹۵۸ بود معرفی نماید به طوریکه محقق بدون آنکه فروضی در مورد نحوه عملکرد درونی سیستم در نظر بگیرد، مدل هایی را برای تحلیل

و پیش بینی پیچیدگی های سیستم بسازد. (مدل سازی غیرتئوریک) فرض کنید مجموعه ای از m متغیر شامل x_1, x_2, \dots, x_m ، و یک متغیر y وجود دارد داده های مربوط به هر کدام از x_i ها و متغیر هدف y متغیر خروجی نیز برای یک دوره زمانی وجود دارد به عبارتی هر یک از متغیرها به صورت یک بردار که شامل اعداد سری زمانی مربوط به آن متغیر است، می باشد. (مادالا و ایواخنکو، ۱۹۴۴).^۸ اطلاعات اولیه ای که جهت ساخت الگوریتم GMDH باید جمع آوری گردد. مجموعه ای از n مشاهده شده است که در ماتریس زیر نشان داده شده است.

برای شروع به کار الگوریتم با دو مسئله مواجه هستیم تشخیص رابطه ای که متغیر خروجی را بر اساس متغیرهای ورودی x_i ها تولید می کند. پیش بینی y به ازای مقادیر معلوم x_i ها به عبارتی نیازه تشخیص مدل و رابطه بین متغیرها می باشد (مدل سازی) که سپس بتوان از روی آن مدل مقادیر آتی متغیر هدف پیش بینی کرد (مادالا و ایواخنکو، ۱۹۹۴).

مبنای الگوریتم GMDH عبارت از فرآیندی جهت ساخت یک چند جمله ای با مراتب بالا است که به سری تابع ولترا^۹ معروف است و به شکل زیر ارائه می گردد: (این چند جمله ای را ایواخنکو نیز می نامند).

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (5)$$

برای این منظور در الگوریتم GMDH ابتدا به تجزیه سری توابع ولترا به چند جمله ای های دو متغیره درجه دوم می پردازیم.

$$Q(x^1, x^1) = a^0 + a^1 x^1 + a^2 x^1 + a^3 x^1 + a^1 x^1 + a^2 x^1 x^1 \quad (6)$$

در این تجزیه سری ولترا به مجموعه ای از معادلات بازگشتی زنجیره ای تبدیل می گردد به گونه ای که مجدداً با جایگذاری جبری هر یک از روابط بازگشتی در این رابطه سری ولترا برقراری گردد.

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}) \quad i = 1, 2, 3, \dots, m \quad (7) \text{ رابطه ی}$$

توسط تابع f ترقیب زده می شود:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}) \quad i = 1, 2, 3, \dots, m \quad (8)$$

و در صورتی که تابع f به صورت زیر بیان شود:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (9)$$

در این صورت رابطه f را می توان به فرم زیر تجزیه نمود:

$$\begin{aligned}
 \hat{y}_k &= G(u_i, u_j) & i, j = 1, 2 (i \neq j) & & k = 1 \\
 \hat{u}_k &= G(s_i, s_j) & i, j = 1, 2, k, F_1 (i \neq j) & & F_1 \leq C_{F_2}^2 & k = 2 \\
 \hat{s}_k &= G(p_i, p_j) & i, j = 1, 2, k, F_2 (i \neq j) & & F_2 \leq C_{F_3}^2 & k = 3 \\
 & \vdots & & & & \\
 \hat{z}_k &= G(w_i, w_j) & i, j = 1, 2, k, F_l (i \neq j) & & F_l \leq C_m^2 & k = F_{l+1} \\
 \hat{w}_k &= G(x_i, x_j) & i, j = 1, 2, k, F_m (i \neq j) & & & k = F_m
 \end{aligned} \tag{10}$$

همان گونه که در معادلات بالا مشاهده می شود ترتیب روابط فوق از بالا به پایین نمایی از پیرویه تجزیه رابطه (۷) توسط معادلات بازگشتی می باشد در واقع هدف این الگوریتم یافتن ضرایب مجهول a در سری توابع و لترامی باشد. لازم به ذکر است که تمامی مدل های جزئی به وجود آمده از یک ساختار متشابه همانند رابطه زیر برخوردار هستند:

$$\hat{f}(x_i, x_j) = v_0 + v_1 x_i + v_2 x_j + v_3 x_i^2 + v_4 x_j^2 + v_5 x_i x_j \tag{11}$$

با توجه به اینکه هدفی را که مادر این الگوریتم دنبال می کنیم چیزی جز مدل سازی سیستم اولیه نیست لذا با ترکیب مدل سیستم های جزئی و تکرار این عمل می توان به مدل اصلی سیستم که به فرم رابطه (۱۲) می باشد دست یافت.

$$\hat{y} = v_0 + \sum_{i=1}^m v_i x_i + \sum_{i=1}^m \sum_{j=1}^m v_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m v_{ijk} x_i x_j x_k + \dots \tag{12}$$

بعد از تجزیه سیستم اصلی به تعداد C_m^2 سیستم جزئی مدلی با دو متغیر ورودی برای هر یک از آنها محاسبه می شود سپس مدل های جزئی ایجاد شده را دو به دو با هم ترکیب کرده که حاصل این ترکیب، تعداد $\frac{C_m^2(C_m^2-1)}{2}$ سیستم و یا مدل جزئی جدید با حداقل سه و چهار متغیر ورودی می باشد البته تعداد متغیرهای وابسته به مدل و یا به عبارتی تعدادی ورودی های سیستم مهم نبوده و تنها دقت تخمین واقعی سیستم اصلی توسط مدل های ایجاد شده اهمیت دارد لذا بادر نظر گرفتن این قاعده برای کاهش محاسبات مضاعف و زائد و افزایش راندمان و دقت مدل سازی تعدادی از مدل های جزئی تشکیل شده را که از دقت و تخمین بالایی نسبت به مدل های دیگر برخوردار هستند انتخاب نموده و مابقی را حذف می کنیم. در دومین مرحله ترکیب مدل های جزئی انتخاب شده و یا به عبارتی سیستم

های ایده آل شکل گرفته در مرحله قبلی مجدداً دو به دو همانند مرحله قبلی ترکیب شده و سیستم های جزئی جدیدی با حداقل پنج و حداکثر شش متغیر ورودی تشکیل می شود به همین طریق در مراحل بعدی نیز با انتخاب و حذف تعدادی از مدل های جزئی ایجاد شده عمل ترکیب آنها ادامه می دهیم تا در نهایت به مدلی نسبتاً ایده آل دست یابیم. هدفی که همواره در پروسه ترکیب مدل های بوجود آمده مورد نظراست دست یافتن به مدلی می باشد که تقریباً تمامی متغیرهای سیستم در آن نمایان و نقش داشته باشند و هدف دیگری که در انجام ترکیب های مکرر مورد نظراست رسیدن به مدلی باشد که میزان خطای خروجی آن نسبت به سایر مدل های محاسبه شده در مراحل قبل کمتر باشد. (لطفی مهر، ۱۳۸۷)


۵) نتایج تحقیق و تفسیر آن

$$ROIL = \ln\left(\frac{oil_t}{oil_{t-1}}\right) = \ln(oil_t) - \ln(oil_{t-1}) = dloil \quad (13)$$

هدف اصلی این تحقیق بررسی عملکرد دقت مدل های ARIMA و GMDH در پیش بینی قیمت نفت خام سنگین ایران بوده، که جهت این منظور از داده های هفتگی طی دوره زمانی هفته سوم ۲۰۰۲/۴ الی هفته چهارم ۲۰۱۱/۷ استفاده شده است. نخستین گام در فرآیند مدل سازی معادله میانگین سری بازدهی قیمت نفت خام داشتن متغیری مانا می باشد. همچنین ضروری است که جهت جلوگیری از ایجاد رگرسیون کاذب از داده های مانا در مدل سازی های داده های سری زمانی استفاده شود. بنابراین، سری لگاریتم قیمت نفت خام سنگین ایران که بر اساس نتایج آزمون های دیکی-فولر تعمیم یافته (و همچنین آزمون فیلیپس-پرون و KPSS)، نامانای و در نتیجه $I(1)$ می باشد (جدول (۱))، ابتدائی بایست از طریق تفاضل گیری مرتبه ی اول مانا گردیده و سپس از سری حاصله (dloil) جهت تصریح مدل ARIMA استفاده شود. سری تفاضل لگاریتم قیمت نفت خام در واقع همان بازده قیمت نفت خام (ROIL=dloil) می باشد. (به همین دلیل در مدل سازی های سری زمانی به کار برده شده از سری بازده قیمت نفت خام سنگین ایران استفاده خواهد شد)


همچنین به کمک تحلیل نموداری نیز می توان به مانا و نامانای بودن یک سری پی برد. به این منظور به مقایسه ی ویژگی های سری های لگاریتم قیمت نفت و بازده قیمت نفت خام ایران می پردازیم.

نمودار (۲): منحنی سری زمانی لگاریتم قیمت نفت خام (LOI L)



منبع: یافته‌های محقق

و بازده قیمت نفت خام سنگین ایران (RLOIL)



منبع: یافته‌های محقق

نمودار (۲) به خوبی نامانایی لگاریتم قیمت نفت خام را می‌رساند. چراکه همانطور که مشاهده می‌شود با گذشت زمان متغیر مذکور (تقریباً) روند صعودی (به همراه شکستگی موجود در سری مذکور) داشته و این امر نتایج آزمون ریشه واحد ارائه شده در جدول (۱) را تأیید می‌کند. بنابراین با انجام تفاضل گیری مرتبه اول می‌توان ضمن مانانمودن این متغیر (Loil) به سری بازدهی قیمت نفت خام (ROIL) نیز دست یافت. به همین منظور به تحلیل سری بازدهی قیمت نفت در نمودار زیر خواهیم پرداخت.

همچنین نمودار ۲ نشان می‌دهد که سری بازده دارای میانگین ثابت (حول صفر) و نیز واریانس ثابت (و غیر وابسته به زمان) بوده که این امر مؤید مانابودن این سری می‌باشد.

باشد. از این روبه راحتی و بدون داشتن واژه ای از ایجاد رگرسیون کاذب، می توان به مدل سازی معادله میانگین این سری به کمک ARIMA پرداخت.

جدول (۱): نتایج مربوط به بررسی مانایی در سری قیمت وبازده نفت خام سنگین ایران

نام متغیر	نوع آزمون مانایی	مقدار آماره بحرانی	مقدار آماره محاسباتی در سطح ۵٪	نتیجه آزمون
loil	ADF	۱/۲۰۱۹	-۱/۹۴۱۵	نامانا
Dloil	ADF	-۱۷/۵۱۹۲	-۲/۸۶۷۳	مانا

منبع: یافته های محقق

در گام بعدی به آزمون لیانگ-باکس (Q_1) جهت بررسی وجود خود همبستگی بین جملات سری بازدهی قیمت نفت می پردازیم. لیانگ و باکس در ۱۹۷۸ آماره Q_{LB} را جهت آزمون این فرضیه که تمامی ضرایب خود همبستگی (ρ_k) به طور هم زمان برابر با صفر هستند (عدم وجود خود همبستگی در اجزاء اخلاص)، بیان نمودند که در آن n حجم نمونه و m طول دوره ی تأخیر می- باشد:

$$Q_{LB} = n(n+2) \sum_{k=1}^m \left(\frac{\hat{\rho}_k^2}{n-k} \right) \sim \chi^2(m) \quad (14)$$

$$\rho_k = \frac{Cov(X_t, X_{t+k})}{Var(X_t)}$$

با استفاده از این آزمون وجود خود همبستگی در سری بازدهی قیمت نفت مورد بررسی قرار گرفت. نتایج این آزمون نیز در جدول (۲) ارائه گردیده است. مقادیر احتمال برای تأخیرهای ۵، ۱۰ و ۲۰ منجر به رد فرض صفر، مبنی بر «عدم حضور خود همبستگی در سری بازدهها» گردیده و در نتیجه وجود خود همبستگی در سری بازدهی قیمت نفت مورد قبول واقع می شود.

جدول (۲) نتایج آزمون لیانگ- باکس برای سری بازدهی قیمت نفت

مقدار احتمال	مقدار بحرانی	آماره Q	مرتبۀ تأخیری
۰/۰۰۰	۸/۰۷۰۵	۳۳/۶۶۵	۵
۰/۰۰۰	۱۸/۳۰۷	۴۰/۰۸۳	۱۰
۰/۰۰۰	۳۱/۴۱۰۴	۴۸/۰۱۴	۲۰

منبع: یافته های محقق

لازم به ذکر است که، نخستین گام در تخمین معادلات میانگین سری‌های مختلفی که دارای خودهمبستگی بوده، تعیین طول وقفه بهینه AR و MA می‌باشد، که این امر می‌تواند براساس متدولوژی باکس- جنکینز صورت بپذیرد (کشاوری حداد و صمدی، ۱۳۸۸). نتایج حالت‌های مختلف تخمین مدل ARIMA، در جدول (۲) ارائه شده است.

جدول (۲): نتایج انتخاب بهترین معادله میانگین سری قیمت نفت

ردیف	مدل	معیار AIC	معیار SBC	DW
۱	AR(1,3)	-3/6364	-3/5948	1/94
۲	MA(1,3)	-3/600	-3/6318	2/007
۳	ARMA(1,1)	-3/6179	-3/5864	1/96
۴	ARMA(2,1)	-3/6150	-3/5762	2/004
۵	ARMA(1,2)	-3/5372	-3/4939	2/021
۶	ARMA(3,(0,0,3)	-3/6667	-3/6472	2/02

منبع: یافته‌های محقق

لازم به ذکر است که اولاً در همه مدل‌های فوق، به غیر از مدل‌های چهارم و پنجم (که در آنها برخی ضرایب بی معنایند) کلیه ضرایب معناداری باشند. ثانیاً مدل‌های فوق در بین کلیه حالات ممکن از بهترین عملکرد برخوردار بوده که در نتیجه نتایج آنها در جدول (۲) ارائه گردیده است، ثالثاً در کلیه مدل‌های فوق معیار دوربین-واتسون دال بر عدم وجود خودهمبستگی در سری مربوطه بوده است. در نهایت براساس معیار اطلاعات، ضریب تعیین مدل‌ها، ضریب دوربین-واتسون و نیز معناداری ضرایب مدل‌های فوق، مدل ARMA(3,0,3) در بین مدل‌های فوق دارای بهترین شرایط می‌باشد.^{۱۰}

نکته قابل توجه آن است که سری بازده قیمت نفت خام دارای اثرات آرچ بوده، از این رو با انجام دوکارمی توان این مشکل را مرتفع ساخت؛ یکی مدل سازی به کمک خانواده مدل‌های GARCH بوده و دیگری استفاده از برآوردهای سازگار و ایست (Robust Regression) می‌باشد. زیرا با توجه به اینکه در این روش خطای معیار به فرم صحیحی تخمین زده می‌شود، دیگر نیازی به دانستن فرم تصریحی معادله واریانس نبوده، و نیز دیگر نگرانی از این بابت نخواهد داشت، که در این پژوهش از روش دوم جهت رفع مشکل مذکور استفاده شده است.

همچنین پس از بررسی پسماندهای مدل ARMA(3003) براساس آماره لیانگ - باکس مشخص شده است که جملات این سری دارای خود همبستگی نمی باشند. بنابراین فرم تصریحی مدل فوق به صورت زیر می باشد

(۱۴)

$$dloil = 0.003 - \{0.013DUM1 + 0.16DUM2 - 0.2DUM3\} + 0.27AR(1) - 0.16AR(2) - 0.24AR(3) - 0.41MA(3)$$

$$t: (1.42) \quad (-3.58) \quad (-4.17) \quad (5.24) \quad (5.83) \quad (-2.37) \quad (-2.08) \quad (3/491)$$

در اینجا ذکر چند نکته از اهمیت به سزایی برخوردار است:

نخست اینکه در کلیه ی مدل های ارائه شده در جدول (۲) از متغیرهای مجازی جهت مدل کردن نقاط بیرون افتاده به منظور افزایش ضریب تعیین مدل ها استفاده شده است. همچنین، هر یک از این متغیرهای مجازی بیانگر وقوع بحران های نفتی در سالهای مختلف می باشد که در زیر به بیان آن می پردازیم:

Dum1: بیانگر بحران نفتی سال ۲۰۰۳ به علت وقوع جنگ آمریکا و عراق

Dum3 و Dum2: بیانگر بحران نفتی سال ۲۰۰۸ به علت بحران مالی آمریکا (پیک بالا و پایین قیمت)

هدف ما در این بخش از پژوهش ساختن یک مدل شبکه ی عصبی از نوع GMDH است که قواعد تحلیل تکنیکی را به عنوان ورودی مورد استفاده قرار می دهد. مزیت قواعد تحلیل تکنیکی در وجود الگوهای قابل بهره برداری درونی آنها است، که میتواند به ارائه نتایج قابل توجهی در انجام پیش بینی ها منتج شود. اصولاً بسیاری از الگوهای موجود در فرآیند تولید داده ی سری های مختلف ممکن است با ابزارهای سنتی قابل شناسایی نباشند، اما به وسیله ی قابلیت تشخیص الگوریتم شبکه های عصبی کشف شوند.

اصولاً یکی از مهمترین کاربردهای مدل های مبتنی بر شبکه عصبی مصنوعی در اقتصاد، بکارگیری آنها در زمینه ی پیش بینی متغیرهای مختلف می باشد. بنابراین، دقت عملکرد مدل های مختلف آنها، براساس معیارهای پیش بینی (که در فصل سوم تشریح شدند) سنجیده می شوند. در این میان، نحوه ی عملکرد شبکه ی عصبی با الگوریتم ژنتیک (GMDH) بدین صورت است که، پس از دریافت اطلاعات از لایه ی ورودی، سعی در یادگیری (آموزش دیدن) فرآیند تولید داده ها می نماید، که در واقع آموزش دیدن این شبکه ها، چیزی جز تنظیم وزن های ارتباطی این نرون ها به ازای دریافت مثال های مختلف نیست. سپس براساس وزن های نرون های مختلف، به غربال سازی نرون های مؤثر و حذف آنها می پردازد. در نهایت، با توجه به این کمیته سازی، ضرایب معادلات جزئی تخمین مجذور خطا (MSE) می پردازد. در نهایت، با توجه به این کمیته سازی، ضرایب معادلات جزئی تخمین

زده شده تا خروجی شبکه به سمت خروجی مطلوب همگرا شود. این پروسه چندین مجموعه ترکیب (از بهترین وزن های نرون ها را ارائه داده، که بر اساس آن‌هایی توان برای هر ترکیب، یک خروجی (\hat{Y}) استخراج نموده و پس از محاسبه ی معیارهای محاسبه ی دقت پیش بینی، به ارزیابی عملکرد مدل های حاصل از ترکیبات استخراجی مختلف (حاصل از بکارگیری الگوریتم GMDH) می پردازیم.

جدول (۳): نتایج تخمین مدل شبکه عصبی الگوریتم GMDH

Input=5lag of dloil			
MAPE	RMSE	MSE	بهترین مدل ها
۰/۰۰۰۷۷۹	۰/۰۴۱۰۲۹	۰/۰۰۱۶۸۳	مدل اول
۰/۰۰۰۸۱۴	۰/۰۴۰۸۶۷	۰/۰۰۱۶۷۰	مدل دوم
۰/۰۰۰۸۱۶	۰/۰۴۰۸۳۸	۰/۰۰۱۶۶۸	مدل سوم
۰/۰۰۰۸۱۸	۰/۰۴۰۷۸۷	۰/۰۰۱۶۶۴	مدل چهارم
۰/۰۰۰۸۱۸	۰/۰۴۰۷۳۵	۰/۰۰۱۶۵۹	مدل پنجم
۰/۰۰۰۸۲۲	۰/۰۴۰۶۱۲	۰/۰۰۱۶۴۹	مدل ششم
۰/۰۰۰۸۳۷	۰/۰۴۰۴۸۸	۰/۰۰۱۶۳۹	مدل هفتم
۰/۰۰۰۸۳۷	۰/۰۴۰۱۶۴	۰/۰۰۱۶۱۳	مدل هشتم
۰/۰۰۰۸۵۹	۰/۰۴۰۱۵۴	۰/۰۰۱۶۱۲	مدل نهم
۰/۰۰۰۸۷۰	۰/۰۴۰۰۱۱	۰/۰۰۱۶۰۱	مدل دهم

منبع: یافته های محقق

نتایج جدول فوق بیانگران است که، بر اساس معیار MSE و RMSE مدل دهم دارای کمترین میزان خطای پیش بینی می باشد. با توجه به اهمیت پیش بینی خارج از نمونه (۵۰ داده) در این قسمت به برآورد معیارهای محاسبه ی دقت پیش بینی مدل های به کار گرفته شده در این پژوهش (مدل ARIMA و مدل شبکه ی عصبی مبتنی بر الگوریتم GMDH) می پردازیم:

جدول (۴): نتایج برآورد دقت پیش بینی مدل های تحقیق

RMSE	MSE	مدل ها
۰/۰۴۱۰۲۴	۰/۰۰۱۶۸۳	ARIMA(1,1)
۰/۰۴۰۰۱۱	۰/۰۰۱۶۰۱	GMDH

منبع: یافته های محقق

باتوجه به معیارهای به دست آمده دقت پیش بینی مدل شبکه عصبی مصنوعی مبتنی بر الگوریتم ژنتیک (GMDHh) از کمترین معیار پیش بینی برخوردار بوده و بنابراین می توان آن را به عنوان بهترین مدل پیش بینی قیمت نفت خام ایران (در بین مدل های بکار برده شده در این پژوهش) یاد کرد.

۵- نتیجه گیری و بحث

اصولاً پیش بینی قیمت هانقش عمده ای در بهینه سازی تولید، بازاریابی و استراتژی بازار دارد. همچنین این امر نقش مؤثری در اجرای سیاست های دولت بازی می کند، چرا که دولت سیاست های خود را نه تنها بر مبنای وضع موجود، بلکه بر مبنای پیش بینی های کوتاه مدت و بلندمدت از متغیرهای کلیدی اقتصادی از جمله قیمت نفت تدوین نموده و به اجرامی گذارد. نفت به عنوان مهمترین کالای سیاسی-اقتصادی، تعیین کننده ی بسیاری از معادلات بین المللی و منطقه ای است. به عبارتی، نفت خام یک کالای مصرفی مهم برای اقتصاد جهانی و یک ماده ی حیاتی برای کشورهای صنعتی و در حال توسعه می باشد.

هدف از این پژوهش، برآورد و ارائه مدلی مناسب جهت پیش بینی قیمت نفت خام سنگین ایران می باشد. در این پژوهش، ابتدا به کمک مدل سازی ساختار موجود در سری قیمت نفت خام بر اساس یک مدل غیر خطی شبکه عصبی مبتنی بر الگوریتم GMDH پرداخته و سپس به مطالعه تطبیقی روش مذکور با یک فرآیند خطی ARIMA در پیش بینی قیمت نفت خام سنگین ایران پرداخته شده است. نتایج این پژوهش بیانگر آن است که مدل شبکه ی عصبی مصنوعی مبتنی بر الگوریتم GMDH دارای عملکرد قابل توجهی در پیش بینی قیمت نفت خام ایران داشته و قادر است که پیش بینی های دقیق تری نسبت به مدل ARIMA ارائه دهد.

فهرست منابع

- ۱) اصفهانیان، مجید و امین نصیری، محمد رضا (۱۳۸۷)، "ارائه یک مدل شبکه عصبی جهت پیش بینی کوتاه مدت قیمت نفت خام" نشریه بین المللی علوم مهندسی دانشگاه علم و صنعت ایران، شماره ۱، جلد ۱۹ صفحات ۳۵-۲۷
- ۲) امامی میبدی، علی، (۱۳۸۵)، "تحلیل عوامل مؤثر بر قیمت نفت خام" فصلنامه پژوهش های اقتصادی ایران، سال هشتم، شماره ۲۸، صفحات ۱۰۷-۱۲۲.

- ۳) پورکاظمی، محمدحسین واسدی، محمدباقر (۱۳۸۸)، "پیش بینی پویایی قیمت نفت خام با استفاده از شبکه های عصبی مصنوعی و بایکارگیری ذخیره سازی های نفتی کشورهای OECD" مجله تحقیقات اقتصادی، شماره ۸۸، صفحات ۲۵-۴۶.
- ۴) دشتی رحمت آبادی، سیدابراهیم و محمدی، حمید وفرج زاده، زکریا، (۱۳۹۰)، "ارزیابی عملکرد الگوهای شبکه عصبی و خودرگرسیون میانگین متحرک در پیش بینی قیمت نفت خام ایران" فصلنامه مطالعات اقتصاد انرژی، شماره ۲۸، صفحات ۹۷-۱۱۸.
- ۵) دلاوری، مجید و باغبان زاده، فرشته (۱۳۸۶). "بررسی آزمون فرضیه عدم تقارن در تابع تقاضای نفت کشورهای عمده و تریدکننده نفت از ایران" فصلنامه مطالعات اقتصاد انرژی، سال چهارم، شماره ۱۴، صفحات ۳۳-۵۱.
- ۶) شکیبایی، علیرضا و نظام آبادی پور، حسین و حسینی، سیدجعفر (۱۳۸۸)، "پیش بینی عرضه نفت خام دریازده کشور تولیدکننده با استفاده از شبکه های عصبی و رگرسیون خطی (۲۰۰۶-۱۹۸۰)" مجله دانش و توسعه، سال شانزدهم، شماره ۲۷، صفحات ۹۸-۱۱۹.
- ۷) فرجام نیا، ایمان و ناصری، محسن و احمدی، سیدمحمد مهدی، (۱۳۸۶)، "پیش بینی قیمت نفت با دو روش ARIMA شبکه عصبی مصنوعی" فصلنامه پژوهش های اقتصادی ایران، شماره ۳۲، صفحات ۱۶۱-۱۸۳.
- ۸) فرجام نیا، ایمان (۱۳۸۴)، "مقایسه پیش بینی قیمت نفت توسط مدل های ANN و ARIMA" پایان نامه کارشناسی ارشد اقتصاد، دانشگاه تهران.
- ۹) کشاورز حداد، غلامرضا و صمدی، باقر (۱۳۸۸)، "برآورد و پیش بینی تلاطم بازدهی در بازار سهام تهران و مقایسه دقت روش هادرتخمین ارزش در معرض خطر: کاربرد آزمون ازم مدل های خانواده FIGARCH" مجله تحقیقات اقتصادی، شماره ۸۶، صفحات ۱۹۳-۲۳۵.
- ۱۰) کیانی، علی، (۱۳۸۶)، "مقایسه سری تحلیل زمانی بارویکردهای شبکه عصبی: مطالعه موردی پیش بینی تولید نفت ایران، شماره ۳۲، صفحات ۱۶۱-۱۸۳.
- ۱۱) لطفی مهر، مهسا، (۱۳۸۷)، "پیش بینی اثر متغیرهای کلان اقتصادی بر شاخص قیمت سهام با استفاده از شبکه ی عصبی GMDH" پایان نامه کارشناسی ارشد رشته اقتصاد نظری، دانشگاه تهران.
- ۱۲) مشیری، سعید و فروتن، فائزه (۱۳۸۳). "آزمون آشوب و پیش بینی قیمت آتی نفت خام" فصلنامه پژوهش های اقتصادی ایران، شماره ۲۱، صفحات ۶۷-۹۰.
- ۱۳) مهرآرا، محسن و همکاران، (۱۳۸۸)، "الگوسازی و پیش بینی شاخص بورس اوراق بهادار تهران و تعیین متغیرهای مؤثر بر آن" فصلنامه پژوهشنامه اقتصادی، شماره ۵۰، صفحات ۳۱-۵۱.
- ۱۴) مهرآرا، محسن و همکاران، (۱۳۸۹)، "پیش بینی بی ثباتی قیمت نفت خام با استفاده از شبکه عصبی GMDH" فصلنامه مطالعه اقتصاد انرژی، سال هفتم، شماره ۲۵، صفحات ۱۲-۸۹.

۱۵) وافی، داریوش، و عرفانی فرد، علی (۱۳۸۹)، "نااطمینانی در بازار آتی های نفت خام و تأثیر آن در پیش بینی قیمت و نوسان درآمدهای نفتی (بازار آه الگوئی مناسب برای پیش بینی قیمت و درآمد نفت خام)" فصلنامه مطالعات اقتصاد انرژی، شماره ۲۵، صفحات ۱۷۷-۱۹۹.

- 1) Mostsfaei, H. & Sakhabakhsh, L. (2011), Modeling and Forecasting of OPEC Oil prices with ARFIMA Model International Journal of Academic Research, Vol3.No,1.
- 2) Choi, K. & S. Hammoudeh, (2009) Long memory in Oil and refined products markets, The Energy Journal, No 30(2) PP97-116.
- 3) Parado .S. (2011) Free lunch in the oil market: a note on Long Memory, Working Paper, No, 23.
- 4) Tsay. W. J. (2008) Analysing Inflation by the ARFIMA Model with Markove-Switching Fractional Differencing Parameter, the Institute of Economics and Academia sinica, Taiwan.
- 5) Cheong, C. W. (2009), Modeling and Forecasting Crude Oil Markets Using ARCH-Type Models, Energy Policy, No. 37, PP2346-2355.
- 6) Madala H. R. Ivakhnenko A. G. (1994) Inductive Learning Algorithms for Complex Systems Modeling CRC Press Inc, Boca, PP. 384.

یادداشت‌ها

¹Prado

²Katsumi Shimotsu

³Choi & Hammoudeh

⁴Cheong

⁵Tesay

⁶Organization for Economic Co-operation and Development

⁷Rosenblatt

⁸Madala & Ivakhnenko

⁹Volterra Functional Series

۱۰- منظور از MA(003) آن است که مدل فوق تنها با وجود MA(3) بهترین عملکرد را داشته و دیگر نیازی به وجود MA(1) و MA(2) در معادله مذکور نیست.