

مقایسه‌ی عملکرد شبکه‌های عصبی و مدل ARIMA در مدل‌سازی و پیش‌بینی کوتاه‌مدت قیمت سبد نفت خام اوپک (با تأکید بر انتظارات تطبیقی)

حسین صادقی\*

استادیار اقتصاد دانشگاه تربیت مدرس sadeghih@modares.ac.ir

مهدی ذوالفقاری

دانشجوی دکتری اقتصاد دانشگاه تربیت مدرس zolfaghari\_mahdi@yahoo.com

مجتبی الهامی نژاد

کارشناس ارشد اقتصاد انرژی دانشگاه صنعت آب و برق elhaminejad.m@yahoo.com

تاریخ دریافت: ۸۸/۱۱/۱ تاریخ پذیرش: ۸۹/۳/۵

چکیده

امروزه نفت به عنوان یکی از منابع مورد استفاده‌ی بشر، از اهمیت ویژه‌ای برخوردار است. قیمت نفت به دلیل اهمیت آن در بازارهای بین‌المللی، رابطه‌ی اساسی با اقتصاد کشورها و موقعیت استراتژیک آن در بین کالاهای اقتصادی، به عنوان یکی از عوامل مؤثر در اقتصاد بین‌الملل، نقش تعیین‌کننده‌ای دارد. شناخت ساختار قیمت این کالا و مدل‌سازی آن همواره مورد توجه پژوهش‌های اقتصادی بوده و تلاش‌هایی نیز برای بررسی علت نوسان و پیش‌بینی آن انجام گرفته است. در این راستا، شبکه‌های عصبی مصنوعی از قابلیت بالایی در مدل‌سازی فرایندهای تصادفی و پیچیده و پیش‌بینی مسیرهای غیرخطی پویا برخوردار هستند. در این مقاله، با استفاده از شبکه‌ی عصبی مصنوعی مبتنی بر انتظارات قیمتی برای داده‌های روزانه، به مدل‌سازی و پیش‌بینی روزانه‌ی قیمت سبد نفت خام اوپک پرداخته شده و نتایج آن با مقادیر پیش‌بینی شده توسط مدل ARIMA براساس معیارهای اندازه‌گیری دقت پیش‌بینی، مورد مقایسه قرار گرفته است. نتایج تحقیق نشان می‌دهد که شبکه‌ی عصبی مورد استفاده، نسبت به مدل ARIMA از قدرت پیش‌بینی بهتری برخوردار است و قیمت نفت خام تابعی از قیمت‌های ۵ روز گذشته‌ی خود می‌باشد.

طبقه‌بندی JEL : C53, E37, Q30

کلید واژه: شبکه‌های عصبی، ARIMA، پیش‌بینی، قیمت سبد نفت خام اوپک، انتظارات تطبیقی

\* نویسنده‌ی مسئول

## ۱- مقدمه

قیمت نفت خام در بازارهای مالی، از مهم‌ترین متغیرهایی است که از یک‌سو، بر ساز و کار اقتصاد کشورهای صادرکننده و واردکننده‌ی نفت و از سوی دیگر فرایند مدیریت و تخمین ریسک مالی پرتفوی سهام شرکت‌های سرمایه‌گذار مؤثر است (مشیری، فروتن، ۱۳۸۳). تغییرات قیمت جهانی نفت در کشورهای صادرکننده‌ی عمده‌ی نفت، سبب بروز بحران‌های مختلف و همچنین تشدید تورم، یا رکود و یا هر دو می‌شود. از آنجایی که در این کشورها سهم بزرگی از درآمدهای اکتسابی دولت را درآمدهای ارزی حاصل از صادرات نفت تشکیل می‌دهد، لذا بررسی چگونگی انتخاب استراتژی‌های صحیح برآورد و پیش‌بینی درآمد هر سال و همچنین تنظیم برنامه و بودجه‌های سالانه جهت سرمایه‌گذاری عمرانی، توسعه‌ی منابع ارزی حاصل از صادرات غیرنفتی، ایمن‌سازی اقتصاد در برابر تغییرات نرخ ارز و ..... برای این کشورها لازم و ضروری است (بیدآباد و پیکارجو، ۱۳۸۷). پیش‌بینی قیمت نقش عمده‌ای در بهینه‌سازی تولید، بازاریابی و استراتژی بازار دارد. علاوه بر این موارد، نقش مؤثری در سیاست‌های دولت بازی می‌کند، چرا که دولت سیاست‌های خود را تنها نه بر مبنای وضع موجود، بلکه بر مبنای پیش‌بینی‌های کوتاه‌مدت و بلندمدت از متغیرهای کلیدی اقتصادی از جمله قیمت نفت تدوین می‌کند و به اجرا می‌گذارد.

بازار نفت یکی از بازارهای پرتلاطم است که پیش‌بینی قیمت‌های آن می‌تواند تأثیر مثبتی در تصمیم‌گیری‌ها داشته باشد. البته وقوع رویدادهای سیاسی، اقتصادی در سطح منطقه‌ای و بین‌المللی تأثیرات ناگهانی در بازار نفت، ایجاد و درجه‌ی اطمینان پیش‌بینی‌های میان‌مدت و بلندمدت را با تردید مواجه می‌کند، اما پیش‌بینی کوتاه‌مدت در صورت صحیح بودن، می‌تواند فرایند تصمیم‌گیری خرید و فروش نفت در بازارهای جهانی را تسهیل و بهترین زمان انجام معاملات را تعیین کند.

در عین حال براساس نظریه‌ی انتظارات تطبیقی فریدمن، متغیرهای قیمتی مورد انتظار (مانند تورم یا قیمت نفت خام)، براساس انتظارات نیروی‌های بازار تحت تجربیات گذشته تعیین می‌شود. تاکنون انتظارات نقش مهمی را در نوسانات قیمت نفت خام به عهده داشته است و به نظر می‌رسد که در مورد قیمت نفت خام (و نرخ بهره) عامل اساسی در تغییرات رفتار واقعی قیمت نفت خام باشد. (امامی میبیدی، ۱۳۸۵). به‌دلیل وجود نوسانات بسیار زیاد و پیچیده، فرایند مولد سری زمانی قیمت نفت خام بیش‌تر به

صورت فرایند تصادفی در نظر گرفته می‌شود (ابریشمی و دیگران، ۱۳۸۶) و از آنجایی که انتظارات تطبیقی برای فرایندهای تصادفی که دارای نواسانات مداوم هستند، مناسب است، پیش‌بینی قیمت‌های انتظاری نفت‌خام تحت این نظریه مفید می‌باشد. در مجموع، از آنجایی که روند تغییرات قیمت در بازارهای بورس انرژی در تصمیم‌گیری‌های معاملاتی از اهمیت فوق‌العاده‌ای برخوردار است، تلاش‌های بسیاری برای به‌کارگیری روش‌های پیش‌بینی در تشخیص فرایندها انجام شده است. از طرفی پیش‌بینی کوتاه‌مدت قیمت نفت برای کاهش اثرات نامطلوب نواسانات قیمت آن مهم است و اهمیت به‌سزایی در نحوه‌ی تصمیم‌گیری سیاست‌گذاران و تصمیم‌گیران اقتصادی در کشورهای مصرف‌کننده و تولیدکننده دارد. بدیهی است که میزان صحت پیش‌بینی می‌تواند از جمله رموز موفقیت این سیاست‌ها باشد.

روش‌های مختلفی برای پیش‌بینی متغیرهای سری زمانی وجود دارد. در حالت کلی روش‌های پیش‌بینی سری زمانی را می‌توان به دو دسته‌ی خطی و غیرخطی تقسیم‌بندی کرد، با این حال پرکاربردترین روش‌های پیش‌بینی خطی، روش‌های فرایند  $ARIMA^1$  و  $ARMA^2$  می‌باشد. امروزه علاقه‌ی فراوانی به استفاده از سیستم‌های هوشمند به منظور بهبود کیفیت تصمیمات مالی به‌وجود آمده است، به‌ویژه شبکه‌های عصبی مصنوعی، که در زمینه‌ی تجزیه و تحلیل و مدل‌سازی روابط غیرخطی یکی از ابزار قدرتمند به حساب می‌آیند. هم‌چنین یکی از روش‌های کارآمد در پیش‌بینی سری‌های زمانی غیرخطی محسوب می‌شود. شبکه‌های عصبی از طریق آموزش و توانایی بالا در یادگیری از تجارب گذشته، در بهبود سطح کارایی خود در این رابطه جایگاه ویژه‌ای دارند.

بخش دوم این مقاله به پیشینه‌ی تحقیق می‌پردازد. در بخش سوم، با مروری بر نظریه‌ی انتظارات تطبیقی، به معرفی شبکه‌ی عصبی پیش‌خور و فرایند  $ARIMA$  پرداخته می‌شود. در بخش چهارم، یک مدل شبکه‌ی عصبی پیش‌خور با در نظر گرفتن انتظارات قیمتی برای داده‌های روزانه‌ی ۲۰۰۳/۹/۱ تا ۲۰۰۹/۹/۱۶، طراحی و مدل‌سازی می‌شود و مدل  $ARIMA$  با همان مجموعه، تخمین زده می‌شود. در بخش پنجم،

1- Auto-Regressive Integrated Moving Average.

2- Auto-Regressive Moving Average .

براساس معیارهای خطا، به ارزیابی دو مدل در زمینه‌ی پیش‌بینی روزانه‌ی قیمت سبب نفت‌خام اوپک به صورت گام به گام (از گام یکم تا گام ششم) پرداخته شده و در پایان نتایج ارائه می‌شود.

## ۲- پیش‌بینی تحقیق

از آن‌جاییکه نفت‌خام یک کالای مصرفی مهم برای اقتصاد جهانی و یک ماده‌ی حیاتی برای کشورهای صنعتی و در حال توسعه می‌باشد، پیش‌بینی قیمت، نقش عمده‌ای در بهینه‌سازی تولید، استراتژی بازار و سیاست‌گذاری‌های دولت دارد. لذا با توجه به اهمیت موضوع، مطالعات مختلفی در زمینه‌ی مدل‌سازی و پیش‌بینی قیمت نفت‌خام انجام گرفته است.

مایکل یه و دیگران<sup>۱</sup> (۲۰۰۲)، با استفاده از داده‌های سطح ذخیره‌سازی، به مدل‌سازی قیمت نفت‌خام وست تگزاس اینترمدیت (WTI) پرداخته‌اند. این الگو مبنای پیش‌بینی اداره‌ی اطلاعات انرژی<sup>۲</sup> وزارت انرژی امریکا قرار گرفته است. در این مدل پیش‌بینی مناسبی در داخل نمونه حاصل آمده است. آن‌ها در مطالعه‌ی دیگری (۲۰۰۵) به پیش‌بینی کوتاه‌مدت قیمت نفت‌خام جنوب تگزاس پرداخته‌اند و تأثیر تغییرات بازار، از جمله موجودی کالا، تولید، واردات و تغییرات تقاضا بر روی قیمت‌های ماهانه‌ی نفت‌خام را بررسی کرده‌اند.

گوری و دیگران<sup>۳</sup> (۲۰۰۷)، در بررسی ارتباط بین قیمت و مصرف نفت، به مطالعه‌ی ۳ سناریو برای قیمت نفت که عبارتند از: رفتار خطی، رفتار سهمی‌گون و رفتار بی‌نظم، پرداخته‌اند. نتیجه آن‌که سری‌های زمانی قیمت نفت با مصرف نفت طی سال‌های ۹۸-۱۹۸۰ همبستگی داشته است. افزایش قیمت نفت در سال ۲۰۰۳، مصرف در همان سال را کاهش داده است. هم‌چنین قیمت نفت به صورت خطی از سال ۱۹۸۰-۲۰۰۳ افزایش یافته، که این منجر به کاهش مصرف طی همین سال‌ها شده است.

کولکرنی و حیدر<sup>۴</sup> (۲۰۰۹)، در مطالعه‌ای به پیش‌بینی قیمت نفت‌خام WTI برای سه روز آینده پرداخته‌اند و این‌طور نتیجه‌گیری کرده‌اند که یک مدل پویا با ۱۳ تأخیر

1- Michael Ye et al.

2- EIA.

3- Gori et al.

4- kulkarni and Haidar.

برای پیش‌بینی کوتاه‌مدت قیمت نقطه‌ای نفت خام، مناسب می‌باشد. هم‌چنین دقت پیش‌بینی قیمت بازار به ترتیب ۰.۷۸٪، ۰.۶۶٪ و ۰.۵۳٪ برای یک، دو و سه روز آینده برآورد شده است.

از مطالعات داخلی انجام گرفته در این زمینه می‌توان به کارهای مشیری و فروتن (۱۳۸۳) اشاره کرد که در مقاله‌ی خود به امکان سنجی وجود آشوب در ساختار سیستم مولد قیمت نفت خام شاخص WTI طی دوره‌ی ۴ آوریل ۱۹۸۳ تا ۱۳ ژانویه‌ی ۲۰۰۳ پرداخته‌اند. در نهایت یک مدل شبکه‌ی عصبی مصنوعی برای پیش‌بینی قیمت‌های آتی نفت خام، طراحی و با نتایج پیش‌بینی مدل خطی ARMA و غیرخطی GARCH<sup>۱</sup> مقایسه شده است. نتایج حاصل نشان داده است که مدل شبکه‌ی عصبی مورد استفاده، نسبت به دو مدل ARMA و GARCH، از قدرت پیش‌بینی بهتری برخوردار می‌باشد. اصفهانیان و ناصری (۱۳۸۴)، از مدل شبکه‌ی عصبی برای پیش‌بینی کوتاه‌مدت نفت خام بهره گرفته و به پیش‌بینی ماهانه‌ی قیمت نفت خام پرداخته‌اند. در فرایند توسعه‌ی این مدل، تأثیر انواع متغیرهای فنی و بنیادی، تعداد نرون‌های لایه‌ی ورودی، تعداد لایه‌ها و نرون‌های پنهان و توابع تبدیل لایه‌ها، پیش‌پردازش مناسب داده‌ها، تقسیمات مختلف داده‌ها برای انتخاب مجموعه‌های آموزشی و آزمایش، انواع الگوریتم یادگیری بهبودیافته و انواع شبکه با انجام آزمایش‌های فراوان بررسی شده اما هیچ یک از متغیرها به جز متغیر تأخیری قیمت نفت خام با وقفه‌های ۱-۹ نتوانسته است نتایج پیش‌بینی شبکه را بهبود بخشد. در نهایت یک شبکه‌ی پیش‌خور سه لایه با میانگین خطای ۷۴ سنت در مجموعه‌ی آموزش و ۷۱ سنت در مجموعه‌ی آزمایش، به عنوان بهترین مدل انتخاب شده است.

زمانی (۱۳۸۴)، در مطالعه‌ی عملکرد بازار بین‌المللی نفت در جهت شناسایی متغیرهای لازم برای الگوسازی را بررسی کرده است، که مهم‌ترین این عوامل ذخیره‌سازی‌های نفت منطقه OECD<sup>۲</sup>، عرضه‌ی اوپک، تقاضای نفت منطقه‌ی غیر OECD و نرخ مؤثر ارز دلار را شامل می‌شود. سپس داده‌ها را از لحاظ آماری، بررسی و روابط بلندمدت بین قیمت WTI و دیگر متغیرها را برآورد کرده است. آن‌گاه مدل‌های خودرگرسیو، تصحیح خطا<sup>۳</sup> (ECM) و خودرگرسیو با وقفه‌های توزیعی<sup>۴</sup> (ARDL) در

1- Generalized autoregressive conditional heteroscedasticity.

2- Organization for economic co-operation and development.

3- Error correction model.

4- Auto regressive distributed.

جهت پیش‌بینی و شناسایی مدل مورد نظر با کم‌ترین خطا استفاده شده‌اند. نشان تحقیق نشان داده است که براساس معیار RMSE، برای داخل نمونه و میزان خطا برای خارج نمونه، نتایج الگوی خودرگرسیو با وقفه‌های توزیعی بهترین وقت پیش‌بینی را ارائه می‌دهد.

معینی و همکاران (۱۳۸۵)، با به‌کارگیری نمای لیاپانوف، به مدل‌سازی سری زمانی قیمت نفت بر پایه‌ی توابع پویا پرداخته‌اند، که براساس آن می‌توان توابع پویای خاصی را برای مدل‌سازی سری زمانی مفروض به کار گرفت. در این مطالعه از تابع لجستیک برای مدل‌سازی قیمت روزانه‌ی نفت در بازه‌ی زمانی ۱۹۹۸-۲۰۰۰ استفاده شده است و این‌طور نتیجه‌گیری شده است که با محاسبه‌ی پارامتر کنترل‌کننده‌ی تابع لجستیک، می‌توان کار پیش‌بینی را برای روندهای لجستیک با طول زمانی ۴ تا ۶ روز، همراه با پایداری مکانیسم بازخور غیرخطی و برای روندهای غیرلجستیک با تأخیر زمانی یک روز و عدم پایداری برای روزهای بعد، با دقت خوبی انجام داد.

بغزیان و نصرآبادی (۱۳۸۵)، با استفاده از سیستم معادلات هم‌زمان و شبکه‌های عصبی، عوامل مؤثر بر مصرف فرآورده‌های نفتی را، تحلیل و تقاضای فرآورده‌های نفتی در طی دوره‌ی ۱۳۸۶ تا ۱۴۰۰ را پیش‌بینی کرده‌اند. در این مطالعه نتایج مدل‌ها در مورد پیش‌بینی رشد مصرف بنزین، نفت‌گاز، نفت سفید و نفت کوره، بر اساس سیستم معادلات هم‌زمان، به‌ترتیب، معادل ۸/۹، ۰/۹، ۰/۱ و ۰/۸ درصد و براساس مدل شبکه‌ی عصبی فازی معادل ۱۰/۱، ۱/۱، ۰/۷ و ۱/۱ درصد می‌باشد.

مدیرشانه‌چی و علیزاده (۱۳۸۵)، با استفاده از شبکه‌های عصبی رگرسیون عمومی<sup>۱</sup>، مدل هوشمندی را برای پیش‌بینی کوتاه‌مدت قیمت نفت ایران (به صورت ماهانه) در دوره‌ی ۱۹۸۵ تا ۲۰۰۳ ارائه کرده‌اند. نتایج شبیه‌سازی نشان داده است که سیستم طراحی شده، کارایی مناسبی در بازه‌های زمانی مختلف از خود نشان می‌دهد. در این مطالعه قیمت‌گذاری نفت ایران بر پایه‌ی قیمت نفت برنت بوده است.

ابریشمی و همکاران (۱۳۸۶)، از مدل‌های اتورگرسیو و واریانس ناهمسان شرطی (ARCH)<sup>۲</sup>، جهت ارزیابی عملکرد مدل‌های پیش‌بینی قیمت نفت استفاده کرده‌اند. در این مطالعه قدرت پیش‌بینی مدل‌های موردنظر با استفاده از معیارهای ارزیابی عملکرد،

1- Generalized Regression Neural Network.

2- Autoregressive conditional heteroscedasticity.

مورد بررسی قرار گرفته است. با توجه به نتایج به دست آمده، مدل‌های (GARCH) بر اساس معیارهای  $MAE^1$ ،  $MAPS^2$ ،  $TARCH^3$  بر اساس معیارهای  $RMSE^4$  و ضریب نابرابری تایل (Theil)، بهترین عملکرد پیش بینی را دارا هستند. همچنین نتایج این تحقیق شواهدی قوی مبنی بر نامتقارن بودن نوسانات قیمت نفت ارائه می‌دهد.

فرجام نیا و همکاران (۱۳۸۶)، با استفاده از دو روش ARIMA و شبکه‌های عصبی مصنوعی، به پیش بینی روزانه‌ی قیمت جهانی نفت خام با ۵ وقفه در دوره‌ی آوریل ۱۹۸۳ تا ژوئن ۲۰۰۵ پرداخته‌اند. همچنین به منظور تشخیص سهم مشارکت هر پارامتر ورودی، در این مدل از تجزیه و تحلیل حساسیت استفاده شده است. نتایج به دست آمده نشان‌دهنده‌ی برتری غیرقابل مقایسه‌ی مدل شبکه‌های عصبی مصنوعی نسبت به مدل ARIMA در پیش بینی قیمت روزانه نفت بوده است.

بیدآباد و پیکارجو (۱۳۸۷)، در مطالعه‌ای با بررسی و شناسایی عوامل اساسی مؤثر بر عرضه و تقاضای نفت خام، از طریق بررسی اثر مازاد عرضه بر بازار جهانی نفت خام، الگویی برای شبیه‌سازی و پیش‌بینی قیمت نفت خام طراحی کرده‌اند. در این الگو که یک الگوی رفتاری هم‌زمان اقتصادسنجی می‌باشد، با استفاده از روش تعدیل عدم تعادل پویا<sup>۵</sup>، اثرات متغیرهای قیمت گاز طبیعی، تولید ناخالص داخلی جهانی، تولید ناخالص داخلی کشورهای تولیدکننده‌ی نفت، ظرفیت تولید نفت خام و مازاد عرضه‌ی نفت در بازار بر قیمت جهانی نفت بررسی شده است. در این مطالعه بر اساس پیش‌بینی‌های انجام شده، قیمت نفت در سال‌های ۲۰۱۰-۲۰۰۸، پس از روندی افزایشی، نزدیک به ۱۰۰ دلار کاهش خواهد یافت؛ ولی این کاهش به کاهش قیمت نفت حدود سال‌های دهه‌ی ۹۰ میلادی نخواهد رسید.

بهرادمهر (۱۳۸۷)، در مطالعه‌ای، با استفاده از هموارسازی موجک و شبکه‌ی عصبی مصنوعی به پیش‌بینی روزانه قیمت نفت خام نیویورک و نفت خام خلیج مکزیک برای دوره‌ی ۲۰۰۰/۱/۴ تا ۲۰۰۴/۹/۲ پرداخته است. در این مطالعه، در مدل ترکیبی، از خاصیت هموارسازی تبدیل موجک برای کاهش سطح نویز داده‌ها استفاده شده و سپس قیمت نفت به وسیله شبکه‌ی عصبی مصنوعی و با داده‌های هموارسازی شده، پیش‌بینی

1- Mean Absolute Error.

2- Mean Absolute percent Square.

3- Threshold autoregressive conditional heteroscedasticity.

4- Root mean squared error.

5- Dynamic Disequilibrium Adjustment Model.

شده است. نتایج حاصل از مقایسه‌ی RMSE مدل‌های رقیب با مدل ترکیبی مورد اشاره، دلالت بر آن دارد که کاهش نویز و هموارسازی داده‌ها، عملکرد پیش‌بینی قیمت نفت را بهبود می‌دهد.

از جمله مطالعات اخیر می‌توان به؛ ابریشمی و همکاران (۱۳۸۹)، اشاره کرد که قیمت گازوئیل خلیج فارس را مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی الگو سازی و پیش‌بینی نمودند. مهرآرا و همکاران (۱۳۸۹) امکان افزایش عایدی حاصل از ناکارایی‌ها در بازار آتی نفت خام را با استفاده از شبکه عصبی بررسی کرده‌اند. مهرآرا و همکاران (۱۳۸۹)، به پیش‌بینی بی‌ثباتی قیمت نفت با استفاده از شبکه عصبی GMDH پرداختند.

غفاری و زارع<sup>۱</sup> (۲۰۰۹)، تغییرات قیمت نفت خام را برای منطقه‌ی مرکزی جنوب تگزاس بررسی و به منظور کاهش تأثیرات اختلالات کوتاه‌مدت غیرقابل پیش‌بینی، از یک الگوریتم برای فیلتر اطلاعات استفاده کرده‌اند. نتیجه این طور نشان داده شده است که برای چندین دوره‌ی انتخاب شده‌ی تصادفی، پیش‌بینی، به طور قابل ملاحظه‌ای از نتیجه‌ی بیش‌تر الگوریتم‌های پیش‌بینی اخیر بالاتر بوده است. برای مطمئن شدن از صحت و اعتبار الگوریتم، چندین پیش‌بینی در طول یک ماه انجام شده و نتایج نشان داده است که پیش‌بینی‌های این دوره‌ها سازگار هستند.

در این مطالعه با توجه به این که روند تغییرات روزانه قیمت نفت خام نوسانی و تصادفی می‌باشد، با معرفی نظریه‌ی انتظارات تطبیقی (که کارایی زیادی در تحلیل روندهای سری زمانی تصادفی دارد) این تئوری در ساختار شبکه‌ی عصبی مصنوعی پیاده شده و با مقایسه‌ی آن با مدل ARIMA، تحت ۴ معیار سنجش خطا، به پیش‌بینی روزانه‌ی قیمت نفت اوپک پرداخته شده است.

### ۳ - مبانی نظری

#### ۳-۱- مروری بر نظریه‌ی انتظارات تطبیقی

در صورتی که سطح قیمت در دوره‌های گذشته به‌طور نامنظم بالا و پایین رفته باشد و هیچ‌گونه جهش و روند افزایشی و یا کاهشی ممتد از خود نشان نداده باشد و به عبارت دیگر به تکرار نوسان کند (مانند قیمت جهانی نفت خام)، در این صورت می‌توان برای پیش‌بینی قیمت‌های آینده از انتظارات تطبیقی استفاده کرد. (برانسون، ترجمه‌ی

1- Ghaffari and Zare.



شاکری، ص ۱۷۷). فریدمن، با مطرح کردن انتظارات تطبیقی که به معنی شکل‌گیری انتظارات تورمی (قیمتی) بر مبنای اطلاعات گذشته می‌باشد، نشان داد که در پیش‌بینی قیمت برای آینده، افراد، براساس خطای پیش‌بینی دوره‌های گذشته و تصحیح درصدی از آن خطا عمل می‌کنند.

براساس این نظریه، سطح قیمت آینده از دو بخش تشکیل می‌شود؛ یکی همان سطح قیمت واقعی مربوط به زمان برآورد و پیش‌بینی ( $t-1$ ) و دیگری عبارتی است که به تعدیل خطای پیش‌بینی در دوره‌ی قبلی مربوط می‌شود که می‌توان اثر قیمت‌های واقعی دوره‌های قبلی را در پیش‌بینی قیمت دوره‌ی بعد در نظر گرفت. البته با طولانی شدن دوره، اثر قیمت‌های واقعی کم‌تر می‌شود، لذا به‌طور طبیعی می‌توان مکانیزم برآورد را به صورت زیر نوشت:

$$P_t = P_{t-1} + \lambda(P_{t-1} - P_{t-2}) \quad (1)$$

اولین جمله در سمت راست رابطه‌ی فوق، سطح قیمت واقعی در زمان  $t-1$  می‌باشد. دومین جمله، همان حاصل ضرب عامل تعدیل  $\lambda$  و خطایی که در پیش‌بینی سطح قیمت مربوط به دوره‌ی  $t-1$  مرتکب می‌شود، می‌باشد.

حال می‌خواهیم نشان دهیم اگر انتظارات به کمک یک مکانیسم تصحیح خطا تعدیل شود، سطح قیمت انتظاری دوره‌ی  $t-1$  تنها به تاریخ و وضعیت قیمت‌های گذشته بستگی دارد و در حقیقت این مکانیسم تصحیح، قیمت انتظاری دوره‌ی  $t-1$  را نسبت به تعیین قیمت واقعی این دوره‌ی  $P_t$  برون‌زا می‌کند.

اگر معادله‌ی (۱) را به یک دوره‌ی عقب‌تر انتقال دهیم، قیمت انتظاری دوره‌ی  $t-1$  برابر است با:

$$P_{t-1} = P_{t-2} + \lambda(P_{t-2} - P_{t-3}) \quad (2)$$

معادله‌ی (۲) را در  $\lambda$  ضرب و حاصل آن را با معادله‌ی (۱) جمع می‌کنیم و به عبارت زیر دست می‌یابیم:

$$P_t = (1-\lambda)P_{t-1} + \lambda(1-\lambda)P_{t-2} + \lambda^2 P_{t-3} \quad (3)$$

روش فوق را تکرار می‌کنیم تا  $P_{t-3}$  از عبارت بالا حذف شود و پس از آن همین روش را در مورد زمان‌های قبلی و قبلی‌تر به کار می‌بریم. تکرار این روند الگوی زیر را ارائه خواهد داد:

$${}_{t-1}P_t = (1-\lambda)P_{t-1} + \lambda(1-\lambda)P_{t-2} + \lambda^2(1-\lambda)P_{t-3} + \lambda^3(1-\lambda)P_{t-4} + \dots \quad (۴)$$

میزان مطلق تصحیح خطا در هر دوره، به پارامتر  $\lambda$  و طول مدت بعد از جهش قیمت بستگی دارد (برانسون، ترجمه‌ی شاکری، ص ۱۷۷).

مفهوم رابطه‌ی (۴) آن است که قیمت انتظاری (پیش‌بینی شده) در دوره‌ی  $t$ ، میانگین وزنی از قیمت‌های واقعی در دوره‌های گذشته است. به عبارت دیگر در پیش‌بینی قیمت (تورم، نفت خام ..... ) دوره‌ی  $t$ ، فرد براساس قیمت واقعی دوره‌های گذشته، پیش‌بینی را انجام می‌دهد. پس آن‌چه به‌طور خلاصه می‌توان گفت آن است که در این شیوه، (شکل‌گیری انتظاری قیمت یا پیش‌بینی قیمت)، فرد گذشته نگر بوده و براساس اطلاعات دوره‌ی گذشته پیش‌بینی خود را انجام می‌دهد.

به‌طور کلی انتظارات تطبیقی در یک محیط اقتصادی که سطح قیمت‌ها به‌طور نسبتاً تصادفی، نوسان می‌کنند و احتمال دائمی بودن تغییرات در شرایط ساختاری و محیط اقتصادی هم بالاست، می‌تواند کارا و منطقی باشد. البته انتقاداتی توسط طرفداران مکتب انتظارات عقلایی بر این نظریه وجود دارد، اما آن‌چه می‌توان گفت این است که این تصور که مردم از گذشته‌ی خود درس می‌گیرند به‌طور حتم عقیده‌ای معقول‌تر از فرض تلویحی انتظارات ایستاست<sup>۱</sup> که طی آن فرض می‌شود افراد از حافظه و تجربیات گذشته تهی باشند. در نهایت به گفته‌ی استفان مک‌نیس<sup>۲</sup> در این باره اکتفا می‌کنیم که «در بهترین حالت ممکن فرضیه‌ی انتظارات تطبیقی تنها به‌عنوان یک وسیله‌ی عملیاتی قابل دفاع است که در حقیقت می‌توان آن را به‌جای فرضیه‌ی پیچیده‌تر مکانیسم متغیر شکل‌گیری انتظارات در تحقیقات مربوطه در نظر گرفت (گجراتی، ترجمه‌ی ابریشمی، ۱۳۸۲).


### ۳-۱- مدل شبکه‌ی عصبی

شبکه‌های عصبی از دهه‌ی ۵۰ شناخته شده بودند، اما تنها در اواسط دهه‌ی ۸۰ بود که الگوریتم‌ها و روش‌های مربوط به شبکه‌های عصبی مصنوعی به‌درجه‌ای از پیشرفت رسیدند که در حل مسائل واقعی از آن‌ها استفاده شد. در حقیقت شبکه‌ی عصبی مصنوعی، مجموعه‌ای از نرون‌های به هم متصل در لایه‌های مختلف هستند که اطلاعاتی

1- Static expectation.

2- Stephen Mc nees.

را برای یکدیگر ارسال می‌کنند. نرون‌های مصنوعی واحدهای ساده‌ی پردازش اطلاعات هستند، بنابراین تعداد زیادی از این نرون‌ها یک شبکه‌ی عصبی را می‌سازند. شکل (۱)، تصویری از یک نرون مصنوعی را نشان می‌دهد.



شکل ۱- نرون مصنوعی با تابع آستانه

همان گونه که در شکل (۱) ملاحظه می‌شود، ارتباطها (سیناپس‌ها)  $W_i$ ، سیگنال‌ها (محرك‌ها)  $U_i$  را به نرون انتقال می‌دهند.  $W_i$  می‌تواند به عنوان یک وزن، که میزان اهمیت ورودی  $U_i$  را نمایش می‌دهد، تفسیر شود. در داخل نرون مجموعه‌ی ورودی‌های وزن دار  $w_i u_i$  در نظر گرفته می‌شود. این مجموع  $u$ ، بزرگ‌تر از حد آستانه‌ی خارجی  $\theta$  در نظر گرفته شده است و نرون خروجی  $Z$  را تولید می‌کند.  $Z$  یک مقدار باینری یا پیوسته است که وابسته به تابع فعالیت می‌باشد. در بیشتر موارد، انتخاب یک تابع فعالیت خروجی، نرون را به برد  $[1, 0]$  یا  $[1, -1]$  محدود می‌باشد.

از دید ریاضی، تساوی زیر یک شرح جامع از نرون‌ها را ارائه می‌نماید:

$$y = \sum_{i=1}^n w_i u_i - \theta \quad \& \quad z = \psi(y) \quad (1)$$

که در آن  $y$ ، ورودی خالص و  $\psi(y)$ ، تابع فعالیت است.

به‌طور کلی نقش نرون‌ها در شبکه‌ی عصبی، پردازش اطلاعات است و این امر در شبکه‌ی عصبی مصنوعی به وسیله‌ی یک پردازشگر ریاضی که همان تابع فعال‌سازی است، انجام می‌گیرد. تابع فعال‌سازی می‌تواند خطی و یا غیرخطی باشد که بر اساس نیاز خاص مسئله که قرار است به‌وسیله‌ی شبکه‌ی عصبی حل شود، از سوی طراح انتخاب می‌شود. برای بهره برداری واقعی از توانایی شبکه‌ی عصبی باید از توابع فعال‌سازی غیرخطی استفاده شود (احمدی، ذوالفقاری، غفار نژاد، ۱۳۸۸). این مسئله

اجازه می‌دهد که شبکه، الگوهای غیرخطی مناسبی از مجموعه‌ی داده‌های پیچیده تولید کند.

رایج‌ترین تابع فعال‌سازی مورد استفاده در ادبیات شبکه‌ی عصبی، تابع توزیع تجمعی لجستیک یا تابع سیگموئید است:

$$\varphi(x) = \frac{1}{1 + e^{-a(x)}} \quad (2)$$

این تابع پیوسته و مشتق پذیر است.

مقدار تابع لجستیک در محدوده‌ی  $[0, 1]$  قرار دارد، به گونه‌ای که وقتی تابع نزدیک به یک می‌شود، نرون نسبت به علائم دریافتی بسیار فعال عمل می‌کند و وقتی تابع به صفر نزدیک می‌شود، نرون به ندرت به علائم دریافتی واکنش نشان می‌دهد. اهمیت طراحی شبکه (تنظیم بین نرون‌ها و سیناپس‌ها) غیرقابل انکار است. یک ارتباط محکم بین الگوریتم یادگیری و ساختار شبکه وجود دارد که طراحی را در مرکزیت قرار می‌دهد.


دو نوع متفاوت از شبکه‌های عصبی تشخیص داده شده است:

(۱) شبکه‌ی عصبی پیش‌خور<sup>۱</sup>

(۲) شبکه‌ی عصبی پس‌خور<sup>۲</sup>

با توجه به این‌که در مقاله‌ی حاضر، از شبکه‌ی عصبی پیش‌خور استفاده شده است، به توضیح در مورد آن بسنده می‌کنیم. یک شبکه‌ی عصبی نوعی، از لایه‌هایی تشکیل شده است. در یک شبکه‌ی دو لایه‌ای، یک لایه‌ی ورودی از منبع نرون‌ها و یک لایه‌ی خروجی از نرون‌ها وجود دارد. یک شبکه‌ی عصبی چند لایه، یک یا چند لایه‌ی پنهانی از نرون‌ها را نیز علاوه بر لایه‌ی ورودی و خروجی دارد. شکل (۲)، نمایشی از شبکه‌ی عصبی ۳ لایه‌ای را نمایش می‌دهد.

1- Feed forward .  
2- Recurrent .



شکل ۲- نمایش شبکه‌ی عصبی با ۳ لایه‌ی ورودی، پنهان و خروجی

ساختار شبکه‌ی عصبی نشان‌داده شده در شکل (۱) دارای یک لایه‌ی ورودی یک لایه‌ی خروجی و یک لایه‌ی بین آن‌ها که مستقیماً به داده‌های ورودی و نتایج خروجی متصل نیست، می‌باشد. در حقیقت این لایه را لایه‌ی مخفی یا پنهان<sup>۱</sup> می‌نامند. لایه‌های مخفی اضافی توانایی شبکه را بالا می‌برند تا آمار بهتری از داده‌های ورودی استخراج کنیم. این موضوع یک کیفیت مهم است، به ویژه آن‌که یک لایه‌ی بزرگ ورودی وجود داشته باشد. اگر هر نرون در هر لایه‌ی شبکه، به هر نرون دیگر در لایه‌ی همسایه‌ی جلویی متصل شده باشد، یک شبکه دارای اتصال کامل است. در ادبیات شبکه‌ی عصبی، به جای اصطلاح تخمین ضرایب از اصطلاح یادگیری یا آموزش برای پیدا کردن ارزش وزن‌های شبکه استفاده می‌شود. دو نوع یادگیری در این ادبیات، مورد بحث قرار می‌گیرد: یادگیری تحت نظارت<sup>۲</sup> و یادگیری بدون نظارت<sup>۳</sup>، در یادگیری بانظارت که به یادگیری با معلم نیز معروف است، ارزش‌های متغیر هدف که شبکه باید بر اساس ارزش‌های متغیرهای ورودی از طریق محاسباتش، آن‌ها را دوباره تولید کند، مشخص می‌باشد، در نتیجه می‌توان خطای پیش‌بینی برای هر مشاهده را به وسیله‌ی محاسبه‌ی اختلاف خروجی شبکه با ارزش‌های متغیرهای هدف اندازه‌گیری و سپس با استفاده از الگوریتم‌های مختلف تکرار، که مشهورترین آن‌ها الگوریتم پس انتشار خطا<sup>۴</sup> می‌باشد، وزن‌های شبکه تعدیل کرد (اصطلاحاً شبکه آموزش داده می‌شود)،

1- hidden layer.

2- Supervised Learning .

3- Unsupervised Learning .

4- Error Back Propagation .

به گونه‌ای که خطای پیش‌بینی داخل نمونه که به‌وسیله‌ی مجموع مربعات خطا یا میانگین خطای مطلق اندازه‌گیری می‌شود، حداقل شود. وقتی که وزن‌ها با هر تکرار تغییر می‌کند، اصطلاحاً گفته می‌شود که شبکه در حال یادگیری است. مهم‌ترین مزیت شبکه‌های عصبی، توانایی در یادگیری از داده‌های ورودی است، بنابراین پتانسیل عمومیت بخشیدن شبکه‌های عصبی به وجود می‌آید. به عبارت دیگر یک خروجی قابل قبول برای داده‌های ورودی دیده نشده‌ی قبلی، ایجاد می‌کند. اهمیت این موضوع در پیش‌بینی بسیار زیاد است. ارزش دیگر این شبکه، طبیعت غیرخطی بودن آن است. به این ترتیب تعداد زیادی از مسائل قابلیت حل پیدا می‌کنند. انعطاف‌پذیری و توانایی عمومیت بخشیدن بدون طرح فرضی لازم از مدل، از جمله مزایای دیگر آن است. شبکه‌ی عصبی پیش‌خور با یک لایه‌ی پنهان، تابع فعال ساز سیگموئید در لایه‌ی پنهان، تابع فعال‌ساز خطی در لایه‌ی خروجی و تعداد نرون‌های کافی در لایه‌ی پنهان، قادر است هر تابعی را با دقت دلخواه تقریب بزند<sup>۱</sup>. به همین علت به این نوع شبکه‌ی عصبی با ساختار فوق، تقریب‌زننده‌ی جامع<sup>۲</sup> گفته می‌شود (اصغری اسکویی، ۱۳۸۱).

### ۳-۲- فرایند ARIMA

فرایند ARIMA(P,d,q)، برای متغیر x را می‌توان به صورت رابطه‌ی (۵) نشان داد:

$$y_t = f(x) + \sum_{i=1}^p \varphi_i y_{t-i} - \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (5)$$

که در آن:

$$y_t = \Delta^d x_t = (1-1)^d x_t \quad (6)$$

و f(t) روند زمانی را (در صورت وجود) در  $y_t$  برآورد می‌کند. در بیش‌تر متغیرهای اقتصادی، معمولاً d=1 بوده، در نتیجه  $f(t) = \mu$  و یا d=0 می‌باشد<sup>۳</sup>:

$$f(t) = \alpha + \delta t \quad (7)$$

در فرایند ARIMA(P,d,q)، به ترتیب بیانگر تعداد جملات خود رگرسیو<sup>۴</sup>،

1- Kuan & White .  
2- Universal Approximator .  
3- Pesaran, H. M. & B. Pesaran .  
4- AR: Auto Regressive .

مرتب‌ه‌ی تفاضل‌گیری و تعداد جملات میانگین متحرک می‌باشند. در صورتی که  $d$  برابر با صفر گردد، فرایند ARIMA تبدیل به فرایند ARMA می‌شود. معمولاً برای تخمین الگوی ARIMA و ARMA از روش باکس-جنکینز استفاده می‌شود که دارای سه مرحله‌ی شناسایی، تخمین و تشخیص دقت پردازش می‌باشد.

تعداد جملات خود رگرسیو و تعداد جملات میانگین متحرک معمولاً با استفاده از توابع خودهمبستگی<sup>۱</sup> (AC) خودهمبستگی جزئی<sup>۲</sup> (PAC) بر اساس مراحل باکس-جنکینز محاسبه می‌شود، اما از آنجایی که ممکن است مدل‌های بهینه‌ی دیگری وجود داشته باشند که بر الگوی مذکور ترجیح داده شوند، این مدل‌ها توسط ضابطه‌های آکائیک و یا شوارتز-بیزین بازبینی می‌شوند، به گونه‌ای که مدلی مناسب محاسب می‌شود که کم‌ترین مقدار آماره‌ی آکائیک و یا شوارتز-بیزین را داشته باشد.

#### ۴- طراحی و تخمین مدل‌ها

داده‌های مورد استفاده در این پژوهش قیمت سبب نفت خام اوپک به صورت روزانه از ۲۰۰۳/۹/۱ تا ۲۰۰۹/۹/۲۲ بوده است، که در مجموع، ۲۰۰۶ مشاهده را دربرمی‌گیرد. داده‌ها از سایت اوپک به دست آمده است. این داده‌ها از دو بخش تشکیل شده‌اند. نخست، داده‌های مربوط به دوره‌ی ۲۰۰۳/۹/۱ تا ۲۰۰۹/۹/۱۶ برای آموزش و آزمایش و بخش دوم، از ۲۰۰۹/۹/۱۷ تا ۲۰۰۹/۹/۲۲ برای اعتبار سنجی و مقایسه‌ی مدل شبکه‌ی عصبی پیش‌خور با فرایند ARIMA مورد استفاده قرار می‌گیرد.

#### ۴-۱- ARIMA

برای پیش‌بینی داده‌های سری زمانی به‌وسیله ARIMA، ابتدا مانایی سری زمانی، بررسی و مرتبه‌ی انباشتگی ( $d$ ) تعیین می‌شود. در مطالعه‌ی حاضر، سری زمانی با تفاضل‌گیری مرتبه‌ی (۱) براساس آزمون دیکي-فولر تعمیم یافته (ADF)<sup>۳</sup>، مانا و سپس تعداد جملات خودرگرسیو ( $p$ ) و تعداد جملات میانگین متحرک ( $p$ )، با استفاده از توابع خودهمبستگی (AC) خودهمبستگی جزئی (PAC) بر اساس مراحل باکس-

1- Auto Coloration .

2- Partial Auto Coloration .

3- Augmented Dickey-Fuller test statistic .

جنکینز محاسبه شده است. اما از آنجایی که ممکن است مدل‌های دیگری وجود داشته باشند که مقدار آکائیک یا شوارتز کم‌تری داشته باشند و بر الگوی مذکور ترجیح داده شوند، مدل‌های دیگر نیز بررسی می‌شوند. بر این اساس، کم‌ترین مقدار آکائیک مربوط به فرایند تعداد جملات خودرگرسیو و میانگین متحرک می‌باشد، که نتایج تفصیلی حاصل از برآورد آن، در جدول (۱) آورده شده است.

جدول ۱- نتایج حاصل از برآورد دوره‌ی ۸۸/۳/۱۵-۸۱/۸/۶

| نام متغیر | ضریب                      | آزمون t | نام متغیر | ضریب  | آزمون t                   |      |      |
|-----------|---------------------------|---------|-----------|-------|---------------------------|------|------|
| C         | عرض از مبدا               | ۰.۰۱    | ۰.۸۴      | AR(3) | تفاضل مرتبه اول با ۳ وقفه | ۰.۰۳ | ۱.۸۷ |
| AR(1)     | تفاضل مرتبه اول با ۱ وقفه | -۰.۴۸   | -۴.۷۲     | MA(1) | جمله اخلاص با ۱ وقفه      | ۰.۷۷ | ۷.۷۳ |
| AR(2)     | تفاضل مرتبه اول با ۲ وقفه | ۰.۱۴    | ۳.۵۸      |       |                           |      |      |

مأخذ: یافته‌های تحقیق

در جدول (۱)، جمله‌ی خودرگرسیو مرتبه‌ی سه AR(3) به لحاظ آماری در سطح خطای ۰/۱۰ معنا دار می‌باشد. بقیه‌ی متغیرها در سطح خطای ۰/۰۱ از نظر آماری معنی دار هستند.

#### ۴-۲- شبکه‌ی عصبی

همان‌طور که در بخش ۳-۱ عنوان شد، بر اساس نظریه‌ی انتظارات تطبیقی، در صورت عدم وقوع یک رویداد خاص در فرایندهای تصادفی، انتظارات قیمتی برای دوره‌های آتی عموماً براساس قیمت‌های واقعی دوره‌های گذشته می‌باشد، لذا با توجه به این نظریه، پیش‌بینی‌های قیمتی روزهای آینده بر اساس نوسانات قیمت‌های واقعی روزهای گذشته در نظر گرفته می‌شود. در این جا ابتدا می‌بایست تعداد روزهایی که قیمت‌های آن‌ها بر انتظارات قیمتی روزهای بعد تأثیر می‌گذارد، تعیین شود و پس از تعیین اثرات هر کدام از این روزها بر این مبنا، قیمت‌های انتظاری (پیش‌بینی شده) روزهای بعد مشخص شود.



در مطالعه‌ی حاضر در شبکه‌ی عصبی برای تعیین تعداد روزهای مؤثر گذشته از معیارهای  $MSE^1$ ، MAPS و  $R^2$  استفاده و با اضافه کردن هر روز (حتی هفته، ماه) به عنوان ورودی در شبکه، مقادیر این معیارها براساس خروجی شبکه محاسبه شده است و تعداد روزهایی که (که بر اساس ورودی‌های مختلف به شبکه داده می‌شد) دارای  $R^2$  بالا و  $MSE$ ، MAPS پایین هستند، به عنوان مدل بهینه انتخاب شده است. پس از اجرای این مرحله، بر اساس مدل بهینه‌ی طراحی شده، قیمت انتظاری روزهای بعد تابعی از قیمت‌های واقعی ۵ روز گذشته می‌باشد. بر این اساس مدل مورد نظر انتخاب و برای پیش‌بینی روزهای بعد با ۵ متغیر توضیحی (نرون ورودی) به شبکه داده شد. انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق می‌تواند استفاده شود. در این تحقیق از شبکه‌ی عصبی چند لایه‌ی پیش‌خور (MFNN)<sup>۲</sup> استفاده شده است. جدول (۲)، چگونگی طراحی و مدل‌سازی سری‌های زمانی قیمت نفت را در شبکه‌ی عصبی نشان می‌دهد.

جدول ۲- طراحی و مدل‌سازی قیمت سید نفت خام اوپک در شبکه‌ی عصبی

| نوع شبکه‌ی عصبی                 | پیش‌خور چند لایه‌ای | الگوریتم آموزش شبکه‌های عصبی       | لونبرگ-مارکوات        |
|---------------------------------|---------------------|------------------------------------|-----------------------|
| تابع فعال‌سازی                  | سیگموئید            | روش توقف فرایند آموزش              | early stopping        |
| تعداد نرون ورودی                | ۵                   | دوره‌ی زمانی آموزش و آزمایش        | ۲۰۰۹/۹/۱۶ - ۲۰۰۲/۵/۳۰ |
| تعداد نرون خروجی                | ۱                   | نسبت تعداد داده‌های آموزش و آزمایش | ۰/۹۰ به ۰/۱۰          |
| معیار تعیین تعداد نرون‌های مخفی | MSE                 | نرخ یادگیری                        | ۰/۰۲                  |
| تعداد لایه‌ی پنهان              | ۱                   | دوره‌ی زمانی پیش‌بینی              | ۲۰۰۹/۹/۲۲ - ۲۰۰۹/۹/۱۷ |
| تعداد نرون‌های پنهان            | ۲۰                  |                                    |                       |

در این مطالعه از شبکه‌ی عصبی پیش‌خور چند لایه، دارای ۲۰ نرون در لایه‌ی مخفی و تابع فعال‌سازی سیگموئید و لایه‌ی خروجی آن استفاده شده است. پس از تعیین تعداد وقفه‌های بهینه، برای انتخاب تعداد نرون‌های لایه‌ی مخفی شبکه،

1- Mean Square Error.

2- Multilayered Feedforward Neural Network.

شبکه‌های مختلف با تعداد نرون‌های مخفی متفاوت طراحی شده و آموزش داده شده است و شبکه‌ی بهینه از میان این شبکه‌ها با توجه به معیار MSE، انتخاب شده یعنی شبکه با کم‌ترین MSE که دارای ۲۰ نرون مخفی می‌باشد، به کار گرفته شده است. لایه‌ی ورودی با توجه به داده‌های ورودی با ۶ نرون در نظر گرفته شده است. تابع فعال‌سازی استفاده شده برای شبکه‌ی مذکور از نوع سیگموئید است. خروجی‌های شبکه، دارای یک نرون و تابع فعال‌سازی خطی<sup>۱</sup> می‌باشد.

از میان الگوریتم‌های مختلفی که برای آموزش شبکه‌های عصبی مورد استفاده قرار می‌گیرد، الگوریتم لونیگ-مارکوات انتخاب می‌شود. چرا که این الگوریتم در مقایسه با سایر الگوریتم‌های پس انتشار خطا دارای سرعت بیش‌تری است. دوره‌ی آموزش و آزمایش، شامل ۲۰۰۰ داده می‌باشد. تعداد داده‌های آموزش و آزمایش مدل به نسبت ۰/۹۰ به ۰/۱۰ تقسیم و از نرخ یادگیری ۰/۰۲ استفاده شده است. برای توقف فرایند آموزش از متد early stopping بهره گرفته شده و در نهایت شبکه‌ی عصبی با استفاده از نرم‌افزار MATLAB(2008)، طراحی و تخمین زده شده است.


##### ۵- ارزیابی مدل‌های پیش‌بینی

بر اساس نتایج به‌دست آمده در مدل ARIMA، قیمت روزانه‌ی نفت تابعی از قیمت‌های دو روز گذشته و جمله‌ی اخلال (خطا) روز گذشته می‌باشد، در حالی که براساس مدل شبکه‌ی عصبی پیش‌خور قیمت نفت تابعی از قیمت‌های ۵ روز گذشته است.

با توجه به این‌که هفته‌ی کاری بازار بورس نفت، ۵ روز می‌باشد و با در نظر گرفتن تأثیرات قیمتی روزهای هفته‌ی جاری، در روزهای هفته بعد به‌ویژه اولین روز هفته، در این مقاله با استفاده از دو روش مذکور قیمت سبد نفت خام اوپک برای ۶ روز آینده پیش‌بینی شده است.

نمودار (۱)، مقادیر پیش‌بینی شده توسط شبکه‌ی عصبی پیش‌خور و فرآیند ARIMA را به همراه مقادیر واقعی برای ۶ روز آینده (۲۰۰۹/۹/۲۲ - ۲۰۰۹/۹/۱۷) نشان می‌دهد.

۱- در ادبیات شبکه‌های عصبی معمولاً منظور از یک تابع فعال‌سازی خطی، استفاده از یک تابع خطی همانی است.



مأخذ: یافته‌های تحقیق

نمودار ۱- مقایسه‌ی نتایج پیش‌بینی بر مبنای شبکه‌ی عصبی و آریمای با مقادیر واقعی

البته از لحاظ فنی با توجه به ساختار شبکه‌های عصبی، با افزایش تعداد دوره‌های پیش‌بینی، دقت پیش‌بینی شبکه‌های عصبی کاهش می‌یابد (مندال و همکاران<sup>۱</sup>، ۲۰۰۶). همچنین از لحاظ تئوری این امکان وجود دارد که با در نظر گرفتن انتظارات، با افزایش تعداد روزهای پیش‌بینی، ضریب اطمینان صحت پیش‌بینی کم‌تر کاهش یابد. زیرا پیش‌بینی روزهای دورتر بر اساس پیش‌بینی روزهای قبل می‌باشد، نه بر پایه‌ی قیمت‌های واقعی.

به منظور مقایسه‌ی قدرت پیش‌بینی فرایند ARIMA و شبکه‌ی عصبی مصنوعی، از معیارهای میانگین مربع خطای استاندارد (MSE)، مجذور میانگین مربع خطای استاندارد (RMSE)، میانگین قدر مطلق خطا (MAE<sup>۲</sup>) و میانگین درصد قدر مطلق خطا (MAPE<sup>۳</sup>) به صورت گام‌به‌گام (روز یکم تا روز ششم استفاده شده که نتایج آن در جدول (۳) آورده شده است) استفاده شده است.

دلیل استفاده از پیش‌بینی نوع گام به گام (روز یکم تا روز ششم) بیان این نکته است که برای مثال، یک مدل، در طول ۶ روز پیش‌بینی، ممکن است در چند روز اول نسبت به مدل دیگر از قدرت پیش‌بینی بالاتری برخوردار باشد، اما در ارزیابی مجموع ۶ روز این گونه نباشد، که توانایی پیش‌بینی این مدل در نوع دوم نادیده گرفته می‌شود.

1- Mandal et al.  
2- Mean Absolute Error.  
3- Mean Absolute Percent Error.

هر گام معرف یک روز است، به عنوان مثال در گام دوم، مدل‌های مذکور برای دو روز آینده پیش‌بینی می‌کنند و در گام چهارم، مدل‌ها برای ۴ روز آینده پیش‌بینی می‌کنند. این معیارها بر اساس مقیاس داده‌های واقعی دوره‌ی ۲۰۰۹/۹/۲۲ - ۲۰۰۹/۹/۱۷ محاسبه شده‌اند.

جدول ۳- مقایسه‌ی قدرت پیش‌بینی مدل‌های شبکه‌ی عصبی و ARIMA

| معیار | گام | شبکه‌ی عصبی | ARIMA | معیار | گام | شبکه‌ی عصبی | ARIMA |
|-------|-----|-------------|-------|-------|-----|-------------|-------|
| MSE   | ۱   | ۰,۲۸        | ۱,۵   | MAE   | ۱   | ۰,۰۷        | ۲,۲۵  |
|       | ۲   | ۰,۳۱        | ۱,۲۷  |       | ۲   | ۰,۱         | ۱,۶۶  |
|       | ۳   | ۰,۳۵        | ۱,۰۹  |       | ۳   | ۰,۱۳        | ۱,۲۹  |
|       | ۴   | ۰,۲۸        | ۱,۳۸  |       | ۴   | ۰,۱         | ۲,۲۴  |
|       | ۵   | ۰,۳۸        | ۱,۴۲  |       | ۵   | ۰,۱۹        | ۲,۳   |
|       | ۶   | ۰,۳۵        | ۱,۲۴  |       | ۶   | ۰,۱۷        | ۱,۹۴  |
| RMSE  | ۱   | ۰,۴۲        | ۲,۲۵  | MAPE  | ۱   | ۰,۲۶        | ۱,۵   |
|       | ۲   | ۰,۴۷        | ۱,۹   |       | ۲   | ۰,۳۱        | ۱,۲۸  |
|       | ۳   | ۰,۵۳        | ۱,۶۲  |       | ۳   | ۰,۳۶        | ۱,۱۳  |
|       | ۴   | ۰,۴۲        | ۲,۰۲  |       | ۴   | ۰,۳۱        | ۱,۴۹  |
|       | ۵   | ۰,۵۶        | ۲,۰۷  |       | ۵   | ۰,۴۳        | ۱,۵۱  |
|       | ۶   | ۰,۵۲        | ۱,۸۱  |       | ۶   | ۰,۴۱        | ۱,۳۹  |

مأخذ: یافته‌های تحقیق

همان‌طور که در جدول (۳) مشاهده می‌شود، مدل شبکه‌ی عصبی پیش‌خور، در تمام گام‌ها و از نظر تمامی معیارهای عملکرد، بر روش ARIMA، برتری قابل توجه‌ای دارد. براساس نتایج به‌دست آمده، مدل شبکه‌ی عصبی پیش‌خور دارای خطای کم‌تر و در نتیجه کارایی بیش‌تر در پیش‌بینی روزهای آینده‌ی قیمت نفت خام است. نباید فراموش کرد که شبکه‌های عصبی معمولاً به تعداد زیادی داده برای آموزش و آزمایش نیاز دارند (حداقل ۵۰ داده)، لذا تغییر در تعداد داده‌های آموزشی و آزمایش و به ویژه کاهش تعداد داده‌های آموزشی، نتایج متفاوتی را به دنبال خواهد داشت.

## ۶- نتیجه‌گیری

پیش‌بینی قیمت نقش زیادی در بهینه‌سازی تولید، بازاریابی و استراتژی بازار دارد. علاوه بر این موارد، نقش مؤثری در سیاست‌های دولت بازی می‌کند، چرا که دولت سیاست‌های خود را فقط نه بر مبنای وضع موجود، بلکه بر مبنای پیش‌بینی‌های کوتاه‌مدت و بلندمدت از متغیرهای کلیدی اقتصادی از جمله قیمت نفت تدوین کرده و به اجرا می‌گذارد. نفت به عنوان مهم‌ترین کالای سیاسی - اقتصادی، تعیین‌کننده‌ی بسیاری از معادلات بین‌المللی و منطقه‌ای است. به عبارتی، نفت خام یک کالای مصرفی مهم برای اقتصاد جهانی و یک ماده‌ی حیاتی برای کشورهای صنعتی و در حال توسعه می‌باشد.

هدف از این تحقیق، برآورد و ارائه‌ی مدل مناسب برای پیش‌بینی کوتاه‌مدت قیمت سبد نفت خام اوپک می‌باشد. در این تحقیق، با مدل‌سازی غیرخطی قیمت سبد نفت خام اوپک به‌وسیله‌ی شبکه‌ی عصبی مصنوعی بر مبنای انتظارات قیمتی، به مطالعه‌ی تطبیقی روش مذکور با فرایند خطی ARIMA در پیش‌بینی قیمت نفت پرداخته شده است. با توجه به جدول (۳)، شبکه‌ی عصبی پیش‌خور از نظر تمامی معیارها عملکرد، بر روش ARIMA برتری دارد. نتایج مطالعه نشان می‌دهد که شبکه‌ی عصبی مصنوعی توانایی بالایی در پیش‌بینی روزانه قیمت سبد نفت خام اوپک دارد و قادر است میزان نوسانات قیمتی را دقیق‌تر از روش ARIMA پیش‌بینی کند.

## فهرست منابع

- ابریشمی، حمید، مهرآرا، محسن و آریانا، یاسمین، (۱۳۸۵)، ارزیابی عملکرد مدل‌های پیش‌بینی بی‌ثباتی قیمت نفت، مجله‌ی تحقیقات اقتصادی، شماره‌ی ۷۸، صص ۲۱-۱.
- ابریشمی، حمید، مهرآرا، محسن، معینی، علی، احراری، مهدی و سلیمانی کیا، فاطمه، (۱۳۸۷)، مدل‌سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه‌های عصبی، فصل‌نامه‌ی پژوهش‌های اقتصادی ایران، سال دوازدهم، شماره‌ی ۳۶، صص ۳۷-۵۸.

ابریشمی، حمید، غنیمی فرد، حجت اله، احراری، مهدی، رضایی، منیژه، (۱۳۸۹)،  
پیش‌بینی قیمت گازوئیل خلیج فارس مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی،  
فصل‌نامه‌ی مطالعات اقتصاد انرژی، مؤسسه مطالعات بین‌المللی انرژی، شماره‌ی ۲۴.

احمدی، علی محمد، ذوالفقاری، مهدی و غفارنژاد، آیدین، (۱۳۸۸)، مطالعه‌ی تطبیقی  
روش‌های ARIMA و شبکه‌ی عصبی مصنوعی در پیش‌بینی نیاز داخلی برق کشور،  
فصل‌نامه‌ی پژوهش‌های اقتصادی ایران، شماره‌ی ۴۱، صص ۱۰۷-۱۲۱.

اصفهانیان، مجید و امین ناصری، محمدرضا (۱۳۸۷)، ارائه‌ی یک مدل شبکه‌ی عصبی  
جهت پیش‌بینی کوتاه‌مدت نفت خام، نشریه‌ی بین‌المللی علوم مهندسی دانشگاه علم و  
صنعت ایران، شماره‌ی ۱، جلد ۳۵، ۱۹-۲۷.

اصغری اسکویی، محمدرضا (۱۳۸۱)، کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های  
زمانی، فصل‌نامه‌ی پژوهش‌های اقتصادی ایران، شماره‌ی ۱۲، صص ۹۵-۶۹.

امامی میبدی، علی (۱۳۸۵)، تحلیل عوامل مؤثر بر قیمت نفت خام، فصل‌نامه‌ی  
پژوهش‌های اقتصادی ایران، سال هشتم، شماره‌ی ۲۸، صص ۱۰۷-۱۲۲.


برانسون، ویلیام اچ، ترجمه‌ی عباس شاکری (۱۳۸۶)، تئوری و سیاست‌های اقتصاد  
کلان، تهران، نشر نی.

بغزیان، آلبرت و نصرآبادی، ابراهیم (۱۳۸۵)، پیش‌بینی مصرف فرآورده‌های نفتی: مقایسه‌ی  
سیستم معادلات اقتصادسنجی و شبکه‌های عصبی، فصل‌نامه‌ی مطالعات اقتصاد انرژی، سال  
سوم، شماره‌ی ۱۰، صص ۶۷-۴۷.

بیدآباد، بیژن و پیکارجو، کامبیز (۱۳۸۷)، شبیه‌سازی و پیش‌بینی قیمت جهانی  
نفت خام، پژوهش‌نامه‌ی اقتصادی، سال هفتم، شماره‌ی ۲۷، صص ۱۱۷-۸۳.

بهرادمهر، نفیسه (۱۳۸۷)، پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و  
شبکه‌ی عصبی مصنوعی، فصل‌نامه‌ی مطالعات اقتصاد انرژی، سال پنجم، شماره‌ی ۱۸،  
صص ۹۸-۸۱.

زمانی، مهرزاد (۱۳۸۴)، مدل‌سازی و پیش‌بینی قیمت نفت خام WTI، فصل‌نامه‌ی  
مطالعات اقتصاد انرژی، سال دوم، شماره‌ی ۴، صص ۳۸-۲۲.



فرجام‌فرایمان، ناصری، محسن و احمدی، سید محمد مهدی (۱۳۸۶)، پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی، فصل‌نامه‌ی پژوهش‌های اقتصادی ایران، سال نهم، شماره‌ی ۳۲، صص ۱۸۳-۱۶۱.

گجراتی، دامور، ترجمه‌ی حمید ابریشمی (۱۳۸۶)، مبانی اقتصاد سنجی، جلد دو، تهران، مؤسسه‌ی انتشارات و چاپ دانشگاه تهران.

مدیرشانه‌چی، محمد حسین و علیزاده، ارغوان (۱۳۸۵)، پیش‌بینی کوتاه‌مدت قیمت نفت با استفاده از شبکه‌ی عصبی، فصل‌نامه‌ی مطالعات اقتصاد انرژی، سال سوم، شماره‌ی ۹، صص ۱-۲۷.

مشیری، سعید و فروتن، فائزه، (۱۳۸۳)، آزمون آشوب و پیش‌بینی قیمت‌های آتی نفت‌خام، فصل‌نامه‌ی پژوهش‌های اقتصادی ایران، شماره‌ی ۲۱، صص ۶۷-۹۰.

معینی، علی، ابریشمی، حمید و احراری، مهدی، (۱۳۸۵)، به‌کارگیری نمای لیاپانوف برای مدل‌سازی سری زمانی قیمت نفت بر پایه‌ی توابع پویا، مجله‌ی تحقیقات اقتصادی، شماره‌ی ۷۶، صص ۷۷-۱۰۰.

مهرآرا، محسن، بهرام‌مهر، نفیسه، احراری، مهدی، محقق، محسن، (۱۳۸۹)، پیش‌بینی بی‌ثباتی قیمت نفت با استفاده از شبکه‌ی عصبی GMDH، فصل‌نامه‌ی مطالعات اقتصاد انرژی، مؤسسه مطالعات بین‌المللی انرژی، شماره‌ی ۲۵.

مهرآرا، محسن، معینی، علی، احراری، مهدی، عرفانی فرد، علی، (۱۳۸۹)، امکان افزایش عایدی حاصل از ناکارایی‌ها در بازار آتی نفت خام، پژوهش‌نامه‌ی اقتصادی، پژوهش‌شده‌ی امور اقتصادی، شماره‌ی ۷، ویژه‌نامه‌ی بازار سرمایه.

Ghaffari, Ali, Zare, Samaneh (2009), A Novel Algorithm for Prediction of Crude Oil Price Variation Based on Soft Computing, Energy Economics, Volume 31, Pages531-536.

Fieder Gori, David Ludovisi, Paulo. Cerritelli, (2007), Forecast of Oil Price and Consumption in the Short Term under Three Scenarios: Parabolic, linear and chaotic behaviour, Energy, Volum 32 , Pages1291-1296.

Michael Ye, John Zyren, Joanne Shore, (2005), A monthly Crude Oil Spot Price Forecasting Model Using Relative Inventories, International Journal of Forecasting, Volume 21, Pages491-501.

---

Michael Ye, John Zyren, And Joanne Shore (2002), Forecasting Crude Oil Spot Price Using OECD Petroleum Inventory Levels, International Advances in Economic Research.

Siddhivinayak Kulkarni, Imad Haidar, (2009), Forecasting Model for Crude Oil Price Using Artificial Neural Networks and Commodity Futures Prices, International Journal of Computer Science and Information Security, Volume 2, Issue1.