

مقایسه توانایی پیش‌بینی مدل‌های VAR، ARIMA و شبکه‌های

عصبی (ANN): تقاضای جهانی نفت اوپک

دکتر شهرام گلستانی*، مصطفی گرگینی** و فاطمه حاج‌عباسی***

تاریخ دریافت: ۷ خرداد ۱۳۹۱ تاریخ پذیرش: ۲۷ آبان ۱۳۹۱

آگاهی از میزان تقاضای آتی نفت به منظور تعیین اولویت‌ها و انتخاب سیاست‌ها در راستای دستیابی به رشد و توسعه اقتصادی، برای کشورهای عضو اوپک ضروری است. پژوهش حاضر، میزان تقاضای نفت اوپک را با استفاده از الگوهای سری زمانی شامل مدل برداری خودرگرسیون (VAR)، مدل خودتوضیح جمعی میانگین متحرک (ARIMA) و الگوی جایگزین، شبکه عصبی مصنوعی با بکارگیری داده‌های ماهانه از ماه اول ۲۰۰۱ تا ماه دهم ۲۰۱۰ پیش‌بینی می‌کند. در همین راستا برای سنجش توانایی قدرت پیش‌بینی الگوهای سه‌گانه از سه معیار مجموع مربعات خطا، میانگین قدرمطلق خطا و معیار میانگین درصد قدرمطلق خطا استفاده شده است. نتایج بدست آمده نشان می‌دهد که الگوی VAR با میزان خطای ۶ درصد برای مجموع مربعات خطا، ۱۹ درصد میانگین قدرمطلق خطا و ۵ درصد میانگین درصد قدرمطلق خطا، مناسب‌ترین پیش‌بینی‌ها را برای تقاضای جهانی نفت اوپک دارد. براساس روش VAR پیش‌بینی می‌شود که تقاضا برای نفت اوپک در ماه‌های سال ۲۰۱۲ رشد داشته باشد. همچنین، پیش‌بینی روند تقاضای جهانی برای نفت این سازمان تا سال ۲۰۱۵ نشان می‌دهد تقاضا برای نفت اوپک روند افزایشی دارد اما از سال ۲۰۱۴ سرعت این روند افزایشی، کندتر می‌شود.

واژه‌های کلیدی: اوپک، تقاضای جهانی نفت، پیش‌بینی.

طبقه‌بندی JEL: Q47، C53، C52، C45، C22.

shahram_golestani@yahoo.com

gorgini2010@gmail.com

abbasif1988@gmail.com

* استادیار دانشکده مدیریت و اقتصاد دانشگاه شهید باهنر کرمان

** دانشجوی کارشناسی ارشد اقتصاد دانشگاه شهید باهنر کرمان

*** دانشجوی کارشناسی ارشد آمار دانشگاه شهید باهنر کرمان

۱. مقدمه

در اقتصادهای وابسته به درآمدهای نفتی از جمله ایران و سایر اعضای اوپک، تحقق برنامه‌های بلندمدت، میان‌مدت و تنظیم بودجه‌های سالانه مستلزم پیش‌بینی‌های نسبتاً دقیق از میزان تقاضای جهانی برای نفت خام و همچنین پیش‌بینی نوسانات قیمت آن است. چنین پیش‌بینی‌هایی این امکان را در اختیار دست‌اندرکاران قرار می‌دهد تا بتوانند با اتکا به جریان پیش‌بینی شده از درآمدهای نفتی، برنامه‌های اقتصادی خود را در راستای دستیابی به رشد و توسعه باثبات و پایدار طراحی و اجرا نمایند. بر این اساس دقت پیش‌بینی‌های انجام گرفته در این چارچوب نقشی کلیدی و مهم را ایفا می‌کند.

روش‌های مختلفی برای پیش‌بینی متغیرهای اقتصادی وجود دارد که از مهمترین آنها می‌توان به پیش‌بینی‌های صورت گرفته در چارچوب تحلیل‌های سری‌های زمانی اشاره نمود. در حالت کلی روش‌های پیش‌بینی سری زمانی را می‌توان به دو دسته خطی و غیرخطی تقسیم‌بندی کرد. با این حال پرکاربردترین روش‌های پیش‌بینی خطی، روش‌های فرایند $ARIMA^1$ و VAR^2 است. به علاوه، امروزه توجه فراوانی به استفاده از سیستم‌های هوشمند در پیش‌بینی متغیرهای اقتصادی معطوف شده است. شبکه‌های عصبی مصنوعی که در زمینه تجزیه و تحلیل و مدل‌سازی روابط غیرخطی یکی از ابزارهای قدرتمند به حساب می‌آیند، یکی از مهمترین سیستم‌های هوشمند محسوب می‌گردند که برای پیش‌بینی متغیرهای اقتصادی بکار گرفته می‌شوند.

در این مقاله تقاضای جهانی برای نفت اوپک در قالب سه الگوی VAR ، $ARIMA$ و ANN^3 مورد پیش‌بینی قرار گرفته است. سپس با استفاده از سه معیار مجموع مربعات خطا (MSE)^۴، میانگین قدرمطلق خطا (MAE)^۵ و معیار میانگین درصد قدرمطلق خطا ($MAPE$)^۶ توانایی و دقت هر کدام از این الگوها در پیش‌بینی تقاضا برای نفت اوپک محاسبه شده است و بهترین الگو در پیش‌بینی تقاضای نفت انتخاب خواهد شد. نهایتاً تقاضای نفت اوپک با استفاده از الگوی برگزیده در دو سناریو یکی برای سال ۲۰۱۲ و دیگری تا پایان سال ۲۰۱۵ مورد پیش‌بینی قرار گرفته است.

-
1. Autoregressive Integrated Moving Average (ARIMA)
 2. Vector Autoregression (VAR)
 3. Artificial Neural Network (ANN)
 4. Mean Squared Error (MSE)
 5. Mean Absolute Error (MAE)
 6. Mean Absolute Percentage Error (MAPE)

۲. ادبیات موضوع

موفقیت شبکه‌های عصبی به عنوان ابزاری قدرتمند به منظور تجزیه و تحلیل داده‌ها، موجب شد تا توجه اقتصاددانان نیز به این روش پیش‌بینی جلب شده و در اواخر دهه ۸۰ میلادی مدل‌های مختلفی جهت پیش‌بینی متغیرهای اقتصادی ساخته شود. در زمینه پیش‌بینی متغیرهای اقتصادی بوسیله شبکه‌های عصبی مصنوعی و مقایسه نتایج با روش‌های دیگر، تحقیقات متفاوت و متعددی انجام شده است.

کاربرد شبکه‌های عصبی مصنوعی در اقتصاد و اقتصادسنجی با مطالعه وایت^۱ در بازارهای مالی و پیش‌بینی قیمت سهام شرکت IBM آغاز شد. نتایج این مطالعه نشان داد که الگوریتم‌های حداقل‌سازی استفاده شده در اقتصادسنجی بهتر از الگوریتم‌های شبکه عصبی است.

نتایج مطالعه وو و لو^۲ نشان داد که در پیش‌بینی کوتاه‌مدت قیمت سهام آمریکا شبکه عصبی مصنوعی در مقایسه با روش ARIMA پیش‌بینی‌های دقیق‌تری ارائه می‌نماید، اما در بلندمدت فرآیند ARIMA توانایی بیشتری در پیش‌بینی دارد.

هیل و دیگران^۳ نتایج پیش‌بینی توسط شبکه‌های عصبی و مدل‌های آماری مختلف را مورد مقایسه قرار داده‌اند. نتایج حاصل بیانگر این بود که پیش‌بینی با شبکه‌های عصبی مصنوعی بهتر از سایر روش‌ها عمل می‌کنند.

کهزادی و دیگران (۱۹۹۵) معاملات سلف ذرت را به روش شبکه‌های عصبی و مدل ARIMA را پیش‌بینی کرده‌اند. نتایج در این تحقیق نشان داد که خطای پیش‌بینی با شبکه عصبی مصنوعی ۱۸ تا ۴۰ درصد کمتر از خطای پیش‌بینی با ARIMA است.

مطالعه پرتوگال^۴ در پیش‌بینی تولید ناخالص بخش صنعت در برزیل با استفاده از داده‌های سری زمانی دوره ژانویه ۱۹۸۱ تا دسامبر ۱۹۹۲ نشان داد که فرآیند ARIMA برتری بیشتری بر مدل شبکه عصبی دارد.

در انگلیس نیز یافته‌های مطالعه چرچ و کورام^۵ نشان داد روش‌های اقتصادسنجی بهتر از شبکه عصبی مصنوعی مخارج مصرف‌کنندگان انگلیس را پیش‌بینی می‌کنند.

-
1. Whit (1988)
 2. Wu and Lu (1993)
 3. Hill, *et al* (1994)
 4. Portugal (1995)
 5. Church and Curram (1996)

فو^۱ رشد تولید ناخالص داخلی واقعی آمریکا را با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون خطی مورد بررسی قرار داده است. نتایج حاصل بیانگر این بود که شبکه‌های عصبی مصنوعی در پیش‌بینی، بهتر عمل می‌کنند.

ژانگ و دیگران^۲ در مقاله خودشان در مورد پیش‌بینی ورشکستگی با استفاده از مدل شبکه عصبی و رگرسیون لاجستیک نشان دادند که دقت کلی پیش‌بینی شبکه‌های عصبی از رگرسیون لاجستیک بیشتر است.

مشیری و کامرون^۳ عملکرد شبکه‌های عصبی مصنوعی با سایر روش‌های اقتصادسنجی و سری زمانی را برای پیش‌بینی نرخ تورم کانادا مقایسه کرده‌اند. آن‌ها مدل‌های شبکه عصبی مصنوعی را با مدل‌های ساختاری VAR، BVAR و ARIMA برای افق‌های زمانی مختلف (یک، سه و دوازده ماه بعد) مقایسه کرده‌اند. معیارهای بکار گرفته شده در این پژوهش، یعنی ریشه میانگین مربع خطاها (RMSE) و میانگین قدر مطلق خطاها (MAE) نشان داد که شبکه‌های عصبی برای پیش‌بینی نرخ تورم کانادا بهتر عمل می‌کنند.

هارنگ و وانگ^۴ یک مدل ساده شبکه‌های عصبی مصنوعی برای مدل‌سازی ARMA برای سری‌های زمانی استفاده کردند. آنها نتیجه گرفتند که هنگامی از داده‌های غیرخطی و پیچیده استفاده می‌کنیم، مدل شبکه‌های عصبی مصنوعی قادر به مدل‌سازی مناسب‌تری برای داده‌ها بوده و این در حالی است که مدل‌های خطی ARMA چنین قابلیتی برای داده‌های غیرخطی ندارند.

همچنین مطالعه تکاز^۵ در زمینه پیش‌بینی تولید ناخالص داخلی کانادا نشان داد که شبکه عصبی مصنوعی تنها در افق‌های زمانی کمتر از ۱۲ ماه دارای خطای پیش‌بینی کمتری در مقایسه با فرآیند خود رگرسیون است و در دوره‌های بیشتر از یک سال مدل VAR جواب‌های دقیق‌تری ارائه می‌کند.

اولسون و ماسمن^۶ از شبکه عصبی برای پیش‌بینی، در گروه‌بندی بازارهای مالی استفاده نمودند. در این مطالعه شبکه عصبی مصنوعی پس از انتشار خطا با مدل لوجیت^۷ و روش حداقل مربعات معمولی (OLS) مقایسه شد. داده‌های بکار رفته در این پژوهش بازده سهام ۲۳۵۲ شرکت

-
1. Fu (1998)
 2. Zhang, *et al* (1999)
 3. Moshiri and Cameron (2000)
 4. Hwang and Wong (2001)
 5. Tkacz (2001)
 6. Olson, *et al* (2003)
 7. Logit

مقایسه توانایی پیش‌بینی مدل‌های VAR، ARIMA و شبکه‌های ... ۱۴۹

کانادایی برای دوره ۱۹۷۶ تا ۱۹۹۳ است. نتایج نشان می‌دهد که شبکه عصبی توانایی بیشتری در شناسایی روابط غیرخطی بین متغیر وابسته و مستقل دارد و لذا پیش‌بینی‌های دقیق‌تری نیز تولید می‌نماید. همچنین شبکه عصبی دقیق‌تر از سایر روش‌ها، شرکت‌ها را براساس بازدهی گروه‌بندی نمود.

هروی و دیگران^۱، توانایی شبکه عصبی مصنوعی را با یک فرایند خودرگرسیون (AR) در پیش‌بینی تولیدات صنعتی سه کشور اروپایی آلمان، فرانسه و انگلیس مورد مقایسه قرار داده‌اند. برای این منظور از معیار ریشه میانگین مجذور خطا (RMSE) استفاده شد. نتایج مطالعه نشان داد که شبکه عصبی مصنوعی در افق‌های زمانی کمتر از ۱۲ ماه دارای خطای پیش‌بینی کمتری در مقایسه با فرایند خودرگرسیونی است.

لونگو و همکاران^۲ الگوهای اقتصادسنجی را برای پیش‌بینی قیمت نفت خام در سه گروه اصلی مدل‌های ساختاری و مختلط، سری زمانی و مالی طبقه‌بندی کردند و سپس به ارزیابی توانایی پیش‌بینی قیمت توسط هر یک از این مدل‌ها با افق‌های مختلف زمانی (سالانه، فصلی، ماهانه و روزانه) پرداختند. نتایج بررسی‌ها حاکی از آن بود که الگوهای تصحیح خطای مالی پیش‌بینی‌های دقیقی از قیمت نقطه‌ای نفت خام ارائه نمی‌دهند و الگوهای پیشنهادی لونگو، تحت عنوان «مدلهای مختلط» با توجه به داده‌ها و معیارهای ارزیابی بکار رفته در مطالعه، به عنوان الگوی برتر شناخته شدند.

از مطالعات داخلی انجام گرفته در این زمینه می‌توان به کارهای مشیری و فروتن (۱۳۸۳) اشاره کرد که به پیش‌بینی قیمت نفت خام با سه روش شبکه عصبی مصنوعی، مدل خطی ARMA و غیرخطی GARCH در دوره چهارم آوریل ۱۹۸۳ تا ۱۳ ژانویه ۲۰۰۳ پرداختند. نتایج بدست آمده نشان می‌دهند که مدل شبکه عصبی مورد استفاده نسبت به دو مدل دیگر از قدرت پیش‌بینی بهتری برخوردار است.

بغزبان و نصرآبادی (۱۳۸۵) با استفاده از سیستم معادلات همزمان و شبکه‌های عصبی، عوامل مؤثر بر مصرف فرآورده‌های نفتی را، تحلیل و تقاضای فرآورده‌های نفتی را در دوره ۱۳۸۶ تا ۱۴۰۰ را پیش‌بینی کرده‌اند. در این مطالعه نتایج مدل‌ها در مورد پیش‌بینی رشد مصرف بنزین، نفت

1. Heravi, *et al* (2004)

2. Longo *et al* (2007)

گاز، نفت سفید و نفت کوره، براساس سیستم معادلات همزمان، به ترتیب معادل ۹/۸، ۹/۰، ۱/۰ و ۸/۰ درصد و براساس مدل شبکه عصبی فازی معادل ۱/۱۰، ۱/۱، ۷/۰ و ۱/۱ درصد است. شبکه‌های عصبی به دلیل ماهیت غیرخطی آن‌ها در دهه‌های اخیر بسیار مورد توجه قرار گرفته‌اند و مقاله‌های فراوانی بر پایه آن‌ها منتشر شده است که از مطالعات اخیر آن‌ها در زمینه نفت می‌توان به مطالعات زیر اشاره کرد. ابریشمی و همکاران (۱۳۸۹)، اشاره کرد که قیمت گازوئیل خلیج فارس را مبتنی بر تحلیل تکنیکی و شبکه عصبی الگوسازی 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^۱ پرداختند.

۳. مروری بر مبانی نظری مدل‌های پیش‌بینی

یکی از اهداف اساسی در تخمین یک مدل رگرسیون این است که بتوان تغییرات متغیر درون‌زا را با مقدار معینی از متغیر برون‌زا پیش‌بینی کرد. پیش‌بینی فرآیندی است که با استفاده از یک مدل عینی یا ذهنی بتوان یک متغیر را برای گذشته یا آینده برآورد نمود. برای پیش‌بینی یک متغیر اول می‌بایست متغیر را در داخل نمونه پیش‌بینی کرد و بهترین روش را انتخاب نمود. سپس متغیر را براساس بهترین مدل برای آینده پیش‌بینی کرد.

پیش‌بینی عمدتاً به دو دسته تقسیم می‌شود: پیش‌بینی در داخل نمونه^۲ و پیش‌بینی خارج از نمونه^۳. در پیش‌بینی داخل نمونه می‌توان متغیر مورد نظر را براساس یک مدل ریاضی یا کیفی برآورد نمود و سپس آن را با متغیر واقعی مقایسه کرد. این امر قدرت مدل‌های پیش‌بینی را می‌سنجد. اما پیش‌بینی خارج از نمونه متغیر مورد نظر را برای دوره‌های آتی یا دوره‌های گذشته (خارج از نمونه) برآورد می‌کند. پیش‌بینی یک متغیر را می‌توان به دو روش انجام داد:

- پیش‌بینی توسط مدل‌های عینی مانند مدل‌های ریاضی، آماری و اقتصادسنجی

1. Group Method of Data Handling

2. In Sample Forecasting

3. Out of Sample Forecasting

- پیش‌بینی توسط مدل‌های ذهنی مانند روش‌های دلفی، کارشناسی، استفاده از تجربیات و اطلاعات خبرگان و ...

در روش ذهنی نیاز به ارائه مدل ریاضی نیست و به صورت کیفی متغیر مورد نظر برآورد می‌شود. اما معمولاً برای انجام فرآیند پیش‌بینی متغیرهای اقتصادی، یعنی برآورد تقریبی یک متغیر اقتصادی در آینده، از مدل‌های ریاضی و آماری استفاده می‌گردد. به بیان دیگر در روش عینی ارائه مدل ضروری است. روش کمی (عینی) با استفاده از سه تکنیک زیر انجام می‌شود.

۱. روش اقتصادسنجی یا ساختاری

۲. روش سری زمانی یا غیرساختاری

۳. روش شبکه‌های عصبی

در روش اول ابتدا یک مدل اقتصادسنجی به صورت زیر برآورد می‌شود:

$$Y = f(X) \quad (1)$$

که Y متغیر وابسته و X برداری از متغیرهای مستقل است. پس از تشکیل توابع و با در دست داشتن متغیرهای X می‌توان متغیر Y را برآورد یا پیش‌بینی کرد. این امر عمدتاً برای پیش‌بینی یک متغیر با استفاده از تغییرات سایر متغیرها صورت می‌پذیرد. به عنوان مثال در برنامه‌های توسعه اقتصادی اگر تابع سرمایه‌گذاری برآورد شود و تابعی از تولید باشد و تولید (X) در سال‌های آتی هدف‌گذاری شود، می‌توان متغیر سرمایه‌گذاری (Y) را پیش‌بینی کرد.

روش دوم که روش غیرساختاری نام دارد یک متغیر به تنهایی و صرفاً براساس تحولات گذشته خودش قابل پیش‌بینی است و نیاز به متغیر دیگری نیست. در این روش مهمترین کار شناسایی رفتار سری زمانی براساس مقادیر پیشین خودش است.

در روش شبکه‌های عصبی، اینکه یک متغیر از چه نوع مدلی تبعیت می‌کند مهم نیست، بلکه با فرآیند یادگیری توسط شبکه، خود شبکه می‌تواند تشخیص دهد که متغیر مورد نظر چگونه در حرکت است و آن را برای دوره‌های آتی پیش‌بینی می‌کند.

باید یادآور شد که بهترین حالت برای پیش‌بینی یک متغیر استفاده از تمام روش‌ها است و پس از پیش‌بینی می‌توان روش‌ها را با مقیاس‌های سنجش پیش‌بینی مقایسه کرد و بهترین روش را انتخاب و از آن برای پیش‌بینی استفاده کرد.

۳-۱. مدل VAR

متدولوژی VAR تا اندازه زیادی به مدل‌های معادلات همزمان شباهت دارد، جز اینکه در این روش با تعدادی متغیرهای درون‌زا سروکار داریم، اما هر متغیر درون‌زا با استفاده از مقادیر گذشته خود و مقادیر باوقفه از تمامی دیگر متغیرهای درون‌زای مدل، توضیح داده می‌شود. معمولاً هیچ گونه متغیر برون‌زایی در مدل وجود ندارد. به علاوه مدل VAR رفتار کوتاه‌مدت متغیرها را با دیگر متغیرها و مقادیر باوقفه خود متغیر را تعیین می‌کند. در یک فرایند خودرگرسیون مدلی که تخمین می‌زنیم عبارت است از

$$Y_t = \alpha + \sum_{j=1}^p \beta_j Y_{t-j} + \sum_{i=1}^q \gamma_i X_{t-i} + U_t \quad (2)$$

که در آن U ها جملات تصادفی بوده که در متدولوژی VAR به عکس‌العمل یا تغییر ناگهانی شهرت دارد.

۳-۲. مدل ARIMA

فرآیند $ARIMA(p,d,q)$ برای متغیر x را می‌توان به صورت رابطه زیر نشان داد:

$$y_t = f(x) + \sum_{i=1}^p \varphi_i y_{t-i} - \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (3)$$

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

در فرایند $ARIMA(p,d,q)$ ، p و d و q به ترتیب بیانگر تعداد وقفه‌های خودرگرسیونی^۱، مرتبه تفاضل‌گیری و تعداد جملات میانگین متحرک است. در صورتی که d برابر با صفر گردد، فرایند $ARIMA$ تبدیل به فرآیند $ARMA$ می‌شود. معمولاً برای تخمین الگوی $ARIMA$ و $ARMA$ از روش باکس-جنکینز استفاده می‌شود که دارای سه مرحله شناسایی، تخمین و تشخیص دقت پردازش است.

تعداد جملات خودرگرسیو و تعداد جملات میانگین متحرک معمولاً با استفاده از توابع خودهمبستگی^۲ (AC) خودهمبستگی جزئی^۳ (PAC) براساس مراحل باکس-جنکینز محاسبه

1. AR: Auto Regressive
2. Auto Coloration
3. Partial Auto Correlation


می‌شود، اما از آنجایی که ممکن است مدل‌های بهینه دیگری وجود داشته باشند که بر الگوی مذکور ترجیح داده شوند، این مدل‌ها توسط معیارهای آکائیک و یا شوارتز-بیزین بازبینی می‌شوند.

۳-۳. مدل شبکه عصبی (ANN)

شبکه‌های عصبی از دهه ۵۰ شناخته شده بودند، اما تنها در اواسط دهه ۸۰ بود که الگوریتم‌ها و روش‌های مربوط به شبکه‌های عصبی مصنوعی به درجه‌ای از پیشرفت رسیدند که در حل مسائل واقعی از آن‌ها استفاده شد. شکل ساده شبکه‌های عصبی مصنوعی (ANN) یک لایه ورودی و یک لایه خروجی دارد. لایه ورودی شامل متغیرهای ورودی از قبیل $x_1, x_2, x_3, \dots, x_n$ که n تعداد متغیرهاست. لایه خروجی نیز شامل متغیرهای خروجی زیادی است از قبیل $y_1, y_2, y_3, \dots, y_n$ ، هر ورودی x به یک خروجی y متصل است. در حقیقت شبکه عصبی مصنوعی، مجموعه‌ای از نرون‌های به هم متصل در لایه‌های مختلف هستند که اطلاعاتی را برای یکدیگر ارسال می‌کنند. نرون‌های مصنوعی واحدهای ساده پردازش اطلاعات هستند، بنابراین تعداد زیادی از این نرون‌ها یک شبکه عصبی را می‌سازند. نمودار ۱ ساختار یک نرون تک ورودی را نشان می‌دهد. اسکالرها p و q به ترتیب ورودی و خروجی هستند.

میزان تأثیر p روی q بوسیله مقدار اسکالر a تعیین می‌شود. ورودی دیگر که به مقدار ثابت ۱ است، در جمله بایاس b ضرب شده، سپس با ap جمع می‌شود. این حاصل جمع، ورودی خالص n برای تابع محرک f خواهد بود. بدین ترتیب، خروجی نرون با معادله زیر تعریف می‌شود:

$$q = f(ap + b) \quad (۴)$$




نمودار ۱. نمایش ساختار یک نرون تک ورودی

نکته‌ای که باید به آن توجه داشت اهمیت و تأثیر جمله بایاس b است. این جمله را می‌توان مانند وزن a در نظر گرفت با این تصور که b میزان تأثیر ورودی ثابت 1 را روی نرون منعکس می‌سازد. باید توجه داشت که پارامترهای a و b قابل تنظیم هستند و تابع محرک f نیز توسط طراح انتخاب می‌شود. براساس این انتخاب و نوع الگوریتم یادگیری، پارامترهای a و b تنظیم می‌شوند. یادگیری بدین معناست که a و b طوری تغییر می‌کنند که رابطه ورودی و خروجی نرون با هدف خاصی مطابقت نماید.^۱ دو نوع متفاوت از شبکه‌های عصبی تشخیص داده شده است:

۱. شبکه عصبی پیش‌خور^۲

۲. شبکه عصبی پس‌خور^۳

با توجه به این که در مقاله حاضر، از شبکه عصبی پیش‌خور استفاده شده است، به توضیح در مورد آن بسنده می‌کنیم. یک شبکه عصبی نوعی، از لایه‌هایی تشکیل شده است. در یک شبکه دو لایه‌ای، یک لایه ورودی از منبع نرون‌ها و یک لایه خروجی از نرون‌ها وجود دارد. یک شبکه عصبی چند لایه، یک یا چند لایه پنهانی از نرون‌ها را نیز علاوه بر لایه ورودی و خروجی دارد. نمودار ۲، نمایشی از شبکه عصبی ۴ لایه‌ای را نمایش می‌دهد.



نمودار ۲. نمایش شبکه عصبی با ۴ لایه ورودی و خروجی^۴

ساختار شبکه عصبی نشان داده شده در نمودار ۱ دارای یک لایه ورودی، یک لایه خروجی و یک لایه بین آن‌ها که مستقیماً به داده‌های ورودی و نتایج خروجی متصل نیست، است. در حقیقت این لایه را لایه مخفی یا پنهان^۵ می‌نامند.

۱. آقایی (۱۳۸۵)، ص ۱۳۶

2. Feed Forward

3. Recurrent

۴. گرفته شده از مقاله خاموشپور (۱۳۸۹) در کنفرانس داده‌کاوی ایران، دانشگاه صنعتی شریف که در این مقاله تعداد لایه‌های ورودی و خروجی نامحدود است اما در مقاله حاضر ۴ لایه ورودی و خروجی در نظر گرفته شده است.

5. Hidden Layer

در ادبیات شبکه عصبی، به جای اصطلاح تخمین ضرایب از اصطلاح یادگیری یا آموزش برای پیدا کردن ارزش وزن‌های شبکه استفاده می‌شود. چگونگی برقراری ارتباط لایه ورودی و خروجی یک شبکه از طریق آموزش شبکه انجام می‌شود. به عبارت دیگر، در جریان یادگیری وزن‌های شبکه W_{ij} تعیین و تنظیم می‌شوند تا در نهایت شبکه قادر به انجام وظیفه خود در ارتباط با پردازش داده‌های ورودی باشد.

در جریان یادگیری اگر در پاسخ شبکه، خطایی وجود داشته باشد، وزن‌های شبکه به طریقی تغییر می‌کنند که در مرحله بعد خطا کاهش یابد و این عمل تا جایی که خطا در حد قابل قبولی باشد، ادامه خواهد داشت. رفتار سیستم‌های یادگیر توسط الگوریتم‌های بازگشتی بیان می‌شود. به همین خاطر به این الگوریتم‌ها، قوانین یادگیری می‌گویند و عموماً توسط معادلات تفاضلی (یا دیفرانسیلی) بیان می‌شوند. این الگوریتم‌ها اطلاعات موجود را پردازش می‌کنند تا شاخص اجرائی (هدف پروسه یادگیری) بهینه گردد. با این کار نقصان اطلاعات اولیه جبران می‌شود.

میزان یادگیری شبکه به درجه کامل بودن اطلاعات بستگی دارد. در حالت کلی دو نوع یادگیری وجود دارد که عبارتند از یادگیری تحت نظارت^۱ و یادگیری بدون نظارت^۲، در یادگیری با نظارت ارزش‌های متغیر هدف که شبکه باید براساس ارزش‌های متغیرهای ورودی از طریق محاسباتش، آن‌ها را دوباره تولید کند، مشخص است. در نتیجه خطای پیش‌بینی برای هر مشاهده را می‌توان بوسیله محاسبه اختلاف خروجی شبکه با ارزش‌های متغیرهای هدف اندازه‌گیری کرد و سپس با استفاده از الگوریتم‌های مختلف تکرار که مشهورترین آن‌ها الگوریتم پس‌انتشار خطا^۳ است، وزن‌های شبکه را تعدیل کرد (اصطلاحاً شبکه آموزش داده می‌شود)، به گونه‌ای که خطای پیش‌بینی داخل نمونه که بوسیله 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 شبکه عصبی، توانایی در یادگیری از داده‌های ورودی است، بنابراین پتانسیل عمومیت بخشیدن شبکه‌های عصبی بوجود می‌آید. به عبارت دیگر یک خروجی قابل قبول برای داده‌های ورودی دیده نشده قبلی، ایجاد می‌کند. اهمیت این موضوع در پیش‌بینی زیاد است. ارزش دیگر این شبکه طبیعت غیرخطی بودن آن است. به این ترتیب تعداد زیادی از مسائل

1. Supervised Learning
2. Unsupervised Learning
3. Error Back Propagation

قابلیت حل پیدا می کنند. انعطاف پذیری و توانایی عمومیت بخشیدن بدون طرح فرضی لازم از مدل، از جمله مزایای دیگر آن است. شبکه عصبی پیش خور با یک لایه پنهان، تابع فعال ساز سیگموئید در لایه پنهان، تابع فعال ساز خطی در لایه خروجی و تعداد نرون های کافی در لایه پنهان، قادر است هر تابعی را با دقت دلخواه تقریب بزند.^۱ به همین دلیل به این نوع شبکه عصبی با ساختار فوق، تقریب زننده جامع^۲ گفته می شود.

۳-۴. معیارهای سنجش قدرت پیش بینی

به منظور مقایسه قدرت پیش بینی و انتخاب بهترین روش پیش بینی، از معیارهای مختلف از جمله، میانگین قدر مطلق خطا (MAE)، میانگین مجذور خطا (MSE) و معیار میانگین درصد قدر مطلق خطا (MAPE) استفاده شد. این معیارها را می توان به صورت روابط زیر نشان داد.

$$MAE = \frac{\sum_{i=1}^n |e_i|}{n} \quad (۵)$$

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} \quad (۶)$$

$$MAPE = \frac{۱۰۰\%}{n} \sum_{i=1}^n \left| \frac{e_i}{y_i} \right| \quad (۷)$$

در این روابط n تعداد پیش بینی ها، e_i خطای پیش بینی است که از تفاوت مقادیر پیش بینی شده و مقادیر واقعی بدست می آید و y_i مقدار واقعی است. از این سه معیار برای سنجش قدرت پیش بینی در این مقاله استفاده خواهد شد.

۴. داده ها و اطلاعات

در این مطالعه، از داده های سری زمانی ماهانه ۲۰۱۰ - ۲۰۰۱ برای پیش بینی تقاضای جهانی نفت اوپک استفاده شده است. داده های مورد استفاده عبارتند از تقاضای برای نفت اوپک، قیمت خود محصول، قیمت کالای جانشین، تولید گروه رقیب و تولید جهانی که به ترتیب با Pg_t ، P_t ، D_t ،

1. Kuan and White
2. Universal Approximator

GDP_t و Qn_t نشان داده شده است. برای بدست آوردن داده‌ها از سایت‌های اوپک، صندوق بین‌المللی پول (IMF)^۱، بانک جهانی^۲، اداره اطلاعات انرژی (EIA)^۳ و Economagic.com استفاده شده است. پس از تعیین متغیرهای الگو، در این مرحله وضعیت ایستایی متغیرها را بررسی می‌کنیم. برای بررسی ایستایی متغیرها در این مطالعه از آزمون دیکی-فولر تعمیم‌یافته، استفاده شده است. نتایج این بررسی در جدول ۱ گزارش شده است.

جدول ۱. نتایج آزمون ایستایی

متغیرها	سطح	تفاضل مرتبه اول	
		مقدار آماره بحرانی (۹۵٪)	مقدار آماره محاسباتی
D_t	مقدار آماره محاسباتی	-۲/۸۹	-۱/۷۸
P_t	مقدار آماره بحرانی (۹۵٪)	-۲/۸۹	-۶/۸۹
Qn_t	مقدار آماره بحرانی (۹۵٪)	-۲/۸۹	-۱۰/۲۳
Pg_t	مقدار آماره بحرانی (۹۵٪)	-۲/۸۹	-۹/۳۸
GDP_t	مقدار آماره بحرانی (۹۵٪)	-۲/۸۹	-

مأخذ: محاسبات پژوهشگر

جدول ۱ نشان می‌دهد از متغیرهای ما سه متغیر اول نا مانا هستند و تنها متغیر آخر ماناست.

۵. تخمین مدل

۵-۱. مدل SVAR^۴

همانگونه که گفته شد، یکی از روش‌های متداول برای پیش‌بینی در سری‌های زمانی استفاده از مدل VAR است. بر این اساس در این قسمت، تقاضای جهانی برای نفت اوپک در چارچوب یک مدل SVAR برآورد می‌گردد. باید توجه شود که مدل بکار گرفته شده در این مقاله مدل SVAR است که این مدل ترکیب مدل VAR و رگرسیون ساختاری است. در این مدل‌ها

1. International Monetary Fund
 2. World Bank
 3. Energy Information Administration
 4. Structural Vector Autoregressions

پیش‌بینی یک متغیر مثل Y نه تنها به مقادیر قبلی خودش بلکه به مقادیر کنونی و گذشته متغیرهای تأثیرگذار بر این متغیر نیز مرتبط است. در مدل‌های SVAR متغیرهای تأثیرگذار می‌توانند به صورت درونزا و یا برونزا در مدل لحاظ گردند. بر این اساس در این مطالعه برای پیش‌بینی به جای مدل VAR از مدل SVAR استفاده شده است. در این مدل تقاضا برای نفت اوپک تابعی از قیمت خود محصول، قیمت کالای جانشین، تولید گروه رقیب و تولید جهانی در نظر گرفته شده است. بر این اساس مدل زیر تصریح گردیده است:

$$D_t = f(P_t, Qn_t, Pg_t, GDP_t, M_t) \quad (۸)$$

که در آن D_t تقاضای جهانی برای نفت اوپک، P_t قیمت جهانی نفت، Qn_t تولیدات نفت غیراوپک، Pg_t قیمت گاز (قیمت کالای جانشین)، GDP_t تولید جهانی هستند و به دلیل اینکه قیمت جهانی نفت در سال ۲۰۰۸ به شدت صعود کرده و دوباره در سال ۲۰۰۹ به روند قبلی خود برگشته به همین دلیل ما M_t متغیر موهومی قیمت جهانی تعریف می‌کنیم و به این صورت است که در سال ۲۰۰۸ این متغیر را یک در نظر گرفته شده و در سال‌های دیگر صفر در نظر می‌گیریم.

۵-۱-۱. تعیین تعداد وقفه‌های بهینه

ما برای تعیین طول وقفه مناسب از معیارهای آزمون‌های نسبت درستنمایی (LR)، آکایک (AIC)، بیزین شوارتز (SC) و حنان کوپین (HQ) طبق جدول ۲ استفاده شده است.

جدول ۲. نتایج آزمون تعیین طول وقفه بهینه الگوی VAR

وقفه	آزمون نسبت درستنمایی (LR)	آکایک (AIC)	بیزین شواتز (SC)	حنان کوپین (HQ)
۰	NA	۶۷/۴۴	۶۷/۵۶	۶۷/۴۹
۱	۷۸۵/۶۳	۶۰/۳۴	۶۰/۳۲	۶۰/۶۳
۲	۳۳/۴۰	۶۰/۴۵	۶۱/۰۷	۶۱/۰۰
۳	۵۰/۲۳	۶۰/۳۷	۶۱/۸۰	۶۱/۱۷

براساس جدول ۲ معیارهای بیزین شوارتز و حنان کوپین نشان‌دهنده وجود یک وقفه در الگوی VAR است. بر این اساس، مدل VAR به صورت زیر تخمین زده شده است.

$$D_t = 0/85 D_{t-1} - 43/49 P g_t \times M_t + 0/0012 GDP_t + 11/77 P_t + 0/19 Q n_t \quad (9)$$

(۷/۲۲) (-۷/۱) (۳۴) (۴/۳) (۴/۲)

$R - Squared = 0/958$

۵-۱-۲. آزمون مرتبه همگرایی

در اینجا هدف از برآورد الگوی VAR، تعیین تعداد روابط بلندمدت بین متغیرهای الگو است. از آنجا که الگو شامل پنج متغیر است، امکان وجود چهار رابطه بلندمدت بین آن‌ها وجود دارد. برای آزمون این مسئله طبق روش جوهانسن از آماره اثر و حداکثر مقدار ویژه استفاده شده که نتایج آن در جدول ۳ ارائه شده است. همانطور که در این جدول دیده می‌شود، هر دو آماره اثر و حداکثر مقدار ویژه وجود حداقل دو رابطه بلندمدت را در سطح ۹۵ درصد اطمینان بین متغیرهای الگو تأیید می‌کند.

جدول ۳. نتایج آزمون تعیین مرتبه همگرایی در الگوی تقاضای نفت اوپک

احتمال	آماره حداکثر مقدار ویژه	مقدار بحرانی (سطح ۵۰/۰)	آماره اثر	فرض H_1	فرض H_0
۰/۰۰	۱۳۰/۰۰	۸۸/۸۰	۰/۴۱	$R > 0$	$R = 0$
۰/۰۲	۶۷/۶۰	۶۳/۸۷	۰/۲۴	$R > 1$	$R = 1$
۰/۲۵	۳۴/۷۳	۴۲/۹۱	۰/۱۳	$R > 2$	$R = 2$
۰/۳۸	۱۷/۴۰	۲۵/۸۷	۰/۱۰	$R > 3$	$R = 3$
۰/۷۱	۴/۱۸	۱۲/۵۱	۰/۰۳۵	$R > 4$	$R = 4$

مأخذ: محاسبات پژوهشگر

با توجه به نتایج جدول ۳ که براساس آن هر دو آماره اثر و حداکثر مقدار ویژه وجود حداقل دو رابطه بلندمدت بین متغیرهای تابع تقاضا برای نفت اوپک را تأیید می‌کند که ما یک رابطه بلندمدت را تحت عنوان مدل جوهانسن برآورد کرده‌ایم.

۳-۱-۵. برآورد مدل جوهانسن

این مدل در واقع روابط بلندمدت را به ما نشان می‌دهد و ما را در سیاستگذاری‌ها کمک می‌کند، در ضمن طبق جدول ۴، این مدل دارای دو رابطه بلندمدت است که در این جا یکی از دو رابطه بیان شده است. در ضمن تمام متغیرها در این رابطه مستقل در نظر گرفته می‌شوند.

$$D = a_1 Pg_t \times M_t + a_2 GDP_t + a_3 P_t + a_4 Qn_t + a_5 @TREND \quad (10)$$

جدول ۴. نتایج برآورد الگوی جوهانسن مربوط به تقاضای نفت اوپک

ضرایب	مقدار عددی	آماره t
a_1	۲۱۳۲/۹۱۵	۱۶۶۹/۰۱
a_2	۲/۶	۰/۳
a_3	-۴۳۴/۷	۲۳۷
a_4	-۱۰/۲۲	۴/۹
a_5	۳۲۰/۴	۱۶۶/۹

مأخذ: محاسبات پژوهشگر

نتایج نشان می‌دهند که در بلندمدت قیمت گاز در پیک قیمتی نفت رابطه معنی‌دار با تقاضای نفت دارد. همچنین این نتایج نشان می‌دهند که در بلندمدت بین قیمت و تقاضا رابطه عکس وجود دارد. در این الگو رابطه معنی‌دار قیمت گاز، قیمت جهانی نفت، تولید غیراوپک و روند با تقاضا برای نفت اوپک مشاهده می‌شود. به این معنی که که ضرایب آنها در سطح یک درصد خطا قابل اطمینان است، اما تولید جهانی نفت در این مدل در سطح خطای بالاتری معنی‌دار است.

۲-۵. برآورد مدل ARIMA

یکی دیگر از الگوهای مورد بررسی الگوی خود وضیح انباشته میانگین متحرک (ARIMA) است. برآورد الگوهای ARIMA دارای چهار مرحله اصلی است که اولین مرحله شناسایی الگو است. شناسایی در برآورد مدل‌های ARIMA با استفاده از نمودارهای خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) صورت می‌گیرد. یکی از شرایط اولیه لازم برای الگو ARIMA، شرط نامانایی متغیر مورد بررسی است. مرحله سوم در روش ARIMA، ارزیابی الگوی برآورد

شده است. معمولاً در این مرحله، برآوردهایی با درجات بالاتر انجام شده و بهترین الگو از بین آنها با توجه به معیارهای آکائیک و شوارتز و همچنین نوفه سفید بودن جملات پسماند انتخاب می‌شود. برای انتخاب الگوی مناسب از معیار آکائیک و شوارتز استفاده شده که بر این اساس الگوی $ARIMA(1,1,1)$ انتخاب شده است. اما از آنجا که هدف اصلی برآورد این الگوها، پیش‌بینی است، میزان خطای پیش‌بینی از اهمیت بیشتری در انتخاب الگو برخوردار است که همان الگویی که با معیار آکائیک انتخاب شد یعنی $ARIMA(1,1,1)$ کمترین خطای پیش‌بینی را داراست. نتایج تفصیلی حاصل از برآورد $ARMA(1,1,1)$ در جدول ۵ آورده شده است.

جدول ۵. نتایج حاصل از برآورد مدل ARIMA برای دوره ۲۰۰۱/۱-۲۰۱۰/۱۰

نام متغیر	ضریب	آزمون t
عرض از مبدا	۵۷/۹	۱/۳
AR(۱)	۰/۸۵	۵/۰۹
AR(۲)	-۰/۱	-۰/۹
AR(۳)	۰/۰۸	۰/۹
MA(۱)	-۰/۸۷	-۶/۲

مأخذ: محاسبات پژوهشگر

در جدول ۵، جمله خودرگرسیو مرتبه اول $AR(1)$ و جمله سوم $AR(3)$ به لحاظ آماری بی‌معنا است. بقیه متغیرها در سطح خطای ۰/۱۰ از نظر آماری معنی‌دار هستند. بنابراین مدل اصلی ما به شکل زیر خواهد شد.

$$D_t = D_{t-1} + 0/85(D_{t-1} - D_{t-2}) - 0/87(\varepsilon_{t-1} - \varepsilon_{t-2}) \quad (11)$$

۳-۵. برآورد مدل شبکه عصبی

کار ساختن شبکه‌های عصبی به طور کلی، بسیار طولانی‌تر از طراحی یک مدل رگرسیون خطی به منظور پیش‌بینی است. طراح شبکه عصبی علاوه بر انتخاب مجموعه‌ای از متغیرهای ورودی، باید ساختمان شبکه‌ای با بهترین پیش‌بینی را شناسایی کند. تغییر ساختمان یک شبکه، حتی بدون تغییر

متغیرهای ورودی و خروجی و اندازه نمونه، می‌تواند پیش‌بینی‌های تولید شده را به طور اساسی تغییر دهد. برای یافتن بهترین ساختمان سازنده شبکه باید با آزمون خطا پیش رفت. همانند دیگر تکنیک‌های تخمین غیرخطی، در این جا نیز نمی‌توان کاملاً مطمئن شد که به حداقل مطلق دست یابیم. نتایج روش تخمین به ارزش‌های اولیه‌ی وزن‌ها حساس است. بنابراین برای یک مجموعه مشخص از ورودی‌ها و یک ساختمان معین شبکه، روش تخمین توقف زود هنگام باید صدها یا هزاران بار با استفاده از ارزش‌های اولیه مختلف وزن‌ها تکرار شود. وزن‌های تخمین زده شده که به کمترین میانگین مربعات خطا (MSE) در مجموعه اعتبار منجر می‌شوند، به عنوان بهترین نتیجه ممکن شبکه برای مجموعه ورودی‌های مشخص که در آن ساختمان شبکه معین مورد استفاده قرار گرفته‌اند، در نظر گرفته می‌شوند.

برای ارزیابی عملکرد دیگر شبکه‌ها، باید با تغییر تعداد لایه‌ها و واحدهای پنهان و اضافه یا حذف کردن ارتباطات میان واحدهای لایه‌های مختلف شبکه، ساختمان شبکه را اصلاح کرد. تمامی مراحل روش تخمین، به امید یافتن حداقل مطلق باید دوباره، صدها بار با ساختمان جدید (با تغییر ارزش‌های اولیه وزن‌ها) تکرار شوند. سپس نتایج تخمین شبکه‌ها با مقایسه MSE حاصل شده در هر ساختمان ارزیابی شود. بعد از ارزیابی شبکه‌های مختلف شبکه‌ای دارای کمترین MSE انتخاب خواهد شد.

مراحل پیش‌بینی توسط شبکه طراحی شده به صورت زیر است:

۱. سری زمانی به کار برده شده داده‌های ماهانه ۲۰۰۱ تا ۲۰۱۰ ماه ۱۰ است که این داده‌ها به صورت جداگانه وارد و نرم‌افزار Matlab می‌شود.
۲. شبکه عصبی مصنوعی با یک لایه پنهان و حداکثر ۴ نرون پنهان و حداکثر ۵ وقفه با الگوریتم لونیبرگ-مارکوات، تابع محرکه لایه پنهان تانزانت هایپربولیک و تابع محرکه لایه خروجی خطی با معیار عملکردش RMSE برای پیش‌بینی تقاضای جهانی برای نفت اوپک اجرا می‌شود.
۳. بهترین نسبت آموزش به آزمون از میان نسبت آموزش به آزمون‌های ۸۰-۲۰، ۸۵-۱۵، ۹۰-۱۰ و ۹۵-۵ درصد، ۹۰-۱۰ درصد با نرخ یادگیری ۲/۰ تعیین می‌شود.
۴. تعداد وقفه‌ها و نرون‌های بهینه مدل محاسبه می‌گردد.
۵. سری زمانی مربوطه پیش‌بینی می‌گردد.

در ضمن ریشه مجموع مربعات خطای هر نوع پیش‌بینی به صورت زیر محاسبه می‌گردد:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n D_t - DF_t}{n}} \quad (۱۲)$$

که در آن DF_t مقدار پیش‌بینی تقاضای نفت اوپک در دوره t ام و D_t مقدار واقعی تقاضای نفت اوپک در دوره t ام است. n نیز تعداد دفعات پیش‌بینی‌ها است. نتایج پیش‌بینی‌های انجام گرفته در جدول‌ها نشان داده شده است.

۶. مقایسه قدرت پیش‌بینی الگوهای سه‌گانه با یکدیگر

در بخش قبل تقاضای جهانی برای نفت اوپک به سه روش VAR و ARIMA و شبکه عصبی مورد برآورد قرار گرفت. در این بخش هدف آن است که این برآوردهای سه‌گانه را با یکدیگر مقایسه نموده و دریابیم که کدامیک از آنها دارای قدرت پیش‌بینی بالاتری است. برای انجام این کار از سه معیار مجموع مربعات خطا (MSE)، میانگین قدرمطلق خطا (MAE) و معیار میانگین درصد قدرمطلق خطا (MAPE) استفاده شده است. بر این اساس دوره پیش‌بینی دوره ۲۰۱۰:۱۰-۲۰۱۰:۱ در نظر گرفته شده است. نتایج حاصل از تخمین هر روش و مقادیر واقعی تقاضا برای نفت اوپک در جدول ۶ ارائه شده است.

جدول ۶. مقدار واقعی و خطای الگوهای VAR، ARIMA و شبکه عصبی تقاضای نفت اوپک برای سال ۲۰۱۰ (میلیون بشکه در روز)

ماه	مقدار واقعی	مقدار پیش‌بینی VAR	مقدار پیش‌بینی ARIMA	مقدار پیش‌بینی شبکه عصبی
ژانویه	۳۴۴۱۴	۳۴/۸۴۱۰۵	۳۴۵۴۴۸۹	۳۴/۳۸۱
فوریه	۳۴۵۱۷	۳۴/۸۴۳۶۴	۳۴۰۱۹۳۵	۳۴/۲۸۹
مارس	۳۴۴۲۹	۳۴/۸۴۶۱۲	۳۴۶۰۱۱۶	۳۵/۲۸۹
آوریل	۳۴۵۱۳	۳۴/۸۴۸۴۸	۳۴۰۷۴۷۶	۳۴/۳۸۱
مه	۳۴۵۹۰	۳۴/۸۵۰۷۳	۳۴۶۵۷۵۲	۳۴/۳۸۱
ژوئن	۳۴۸۴۷	۳۴/۸۵۲۸۸	۳۴۱۳۰۲۷	۳۴/۳۸۱
جولای	۳۴۸۷	۳۴/۸۵۴۹۳	۳۴۷۱۳۹۸	۳۴/۷۸۱
آگوست	۳۴۸۷	۳۴۸۵۶۸۹	۳۴۱۸۵۸۷	۳۴/۵۸۱

۳۴/۷۸۱	۳۴۷۷۰۵۲	۳۴۸۵۸۷۶	۳۴۸۲	سپتامبر
۳۴/۷۸۱	۳۴۳۴۱۵۵	۳۴۸۶۰۵۵	۳۴۹۰	اکتبر

مأخذ: محاسبات پژوهشگر

حال به این پرسش می‌پردازیم که کدام یک از این سه روش پیش‌بینی خطای کمتری را دارند؟ برای پی بردن به پاسخ پرسش بالا، ما داده‌های واقعی ۱۰ ماه آخر سال ۲۰۱۰ را با مقادیر پیش‌بینی شده با این سه روش مقایسه می‌کنیم و هر کدام که خطای کمتری داشت را به عنوان معیار در نظر می‌گیریم. در ضمن هر چه دوره پیش‌بینی طولانی‌تر می‌شود، مقدار خطای پیش‌بینی نیز بیشتر می‌شود چرا که پیش‌بینی در هر دوره، مجموع خطای پیش‌بینی‌های گذشته را نیز در خود دارد. برای تعیین میزان کمی خطاهای پیش‌بینی از آماره‌های مجموع مربعات خطا (MSE)، میانگین قدرمطلق خطا (MAE) و معیار میانگین درصد قدرمطلق خطا (MAPE) استفاده شده که نتایج آن در جدول ۷ آمده است.

جدول ۷. مقایسه توانایی الگوهای مختلف در پیش‌بینی تقاضای نفت اوپک

معیار میانگین درصد قدرمطلق خطا (MAPE)	میانگین قدرمطلق خطا (MAE)	مجموع مربعات خطا (MSE)	نوع الگو
۵٪	۰/۱۹۰	۰/۰۶۵	VAR
۱۰٪	۰/۳۵۲	۰/۱۹۴	ARIMA
۷٪	۰/۲۴	۰/۱۱۷	ANN

مأخذ: محاسبات پژوهشگر

ارزیابی قدرت پیش‌بینی الگوی VAR و مقایسه آن با الگوهای ARIMA و شبکه عصبی حاکی از تفاوت در میزان صحت پیش‌بینی این الگو نسبت به سایر الگوهاست. همانطور که در جدول ۷ مشاهده می‌شود، الگوی VAR کمترین خطا در پیش‌بینی تقاضای جهانی نفت اوپک دارد.

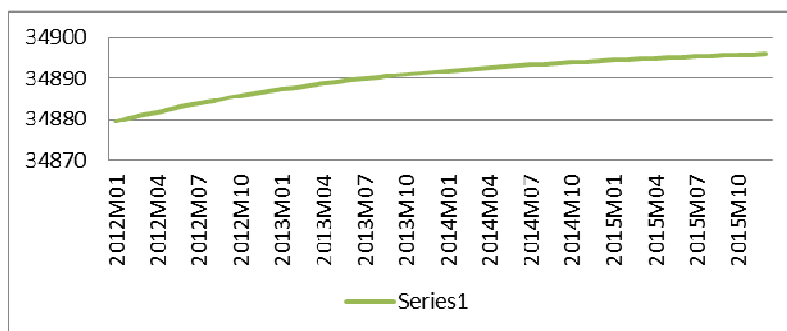
۷. پیش‌بینی آتی تقاضا برای نفت اوپک

معیار پیش‌بینی را الگوی VAR قرار داده و ماه‌های سال ۲۰۱۲ را با این روش پیش‌بینی کرده و نتایج را در جدول ۸ آورده که نشان‌دهنده این است که در سال ۲۰۱۲ رشد تقاضا برای نفت اوپک وجود دارد.

جدول ۸. پیش‌بینی تقاضای جهانی برای نفت اوپک به روش VAR برای سال ۲۰۱۲
(میلیون بشکه در روز)

ماه	مقدار پیش‌بینی	ماه	مقدار پیش‌بینی
ژانویه	۳۴/۸۷۹۳۶	جولای	۳۴/۸۸۳۸۹
فوریه	۳۴/۸۸۰۲۰	آگوست	۳۴/۸۸۴۵۲
مارس	۳۴/۸۸۱۰۱	سپتامبر	۳۴/۸۸۵۱۳
آوریل	۳۴/۸۸۱۷۸	اکتبر	۳۴/۸۸۵۷۲
مه	۳۴/۸۸۲۵۱	نوامبر	۳۴/۸۸۶۲۷
ژوئن	۳۴/۸۸۳۲۲	دسامبر	۳۴/۸۸۶۸۰

مأخذ: محاسبات پژوهشگر



نمودار ۳. روند پیش‌بینی تقاضای جهانی برای نفت اوپک برای دوره زمانی ۲۰۱۱-۲۰۱۵

مأخذ: محاسبات پژوهشگر

همانطور که نمودار ۳ نشان می‌دهد تقاضا برای نفت اوپک روند افزایشی دارد اما از سال ۲۰۱۴ سرعت افزایشی این روند کندتر می‌شود، به طوری که در ماه‌های سال ۲۰۱۵ اختلاف تقاضا برای نفت اوپک به کمترین حد خود می‌رسد و این می‌تواند هشدار برای کشورهای باشد (که عضو اوپک هستند) که صادرات نفت بیشترین سهم در صادرات آن کشورها دارد.

۸. جمع بندی و نتیجه گیری

از آنجایی که سازمان اوپک نقش مهمی را در طرف عرضه جهانی نفت بر عهده دارد و میزان تولید کل این سازمان و نیز سهمیه تعیین شده برای هر یک از اعضا در هر دوره باید براساس میزان تقاضای جهانی برای این محصول و عرضه سایر تولیدکنندگان تعیین گردد، از این رو انجام پیش‌بینی‌های دقیق در ارتباط با میزان تقاضا برای نفت این سازمان امری لازم و حیاتی است. بر این اساس در این مطالعه به منظور پیش‌بینی تقاضای جهانی برای نفت اوپک، ابتدا تقاضای جهانی برای نفت این سازمان براساس سه مدل VAR، ARIMA و شبکه عصبی (ANN) تخمین زده شد. سپس با بکارگیری سه معیار مجموع مربعات خطا، میانگین قدرمطلق خطا و میانگین درصد قدرمطلق خطا بهترین مدل انتخاب گردید. نتایج بدست آمده بیانگر آن است که مدل VAR از میان این سه مدل توانایی بیشتری را برای پیش‌بینی تقاضای جهانی نفت اوپک داراست. در نهایت با توجه به دقت بیشتر پیش‌بینی الگوی VAR با میزان خطای ۶ درصد برای مجموع مربعات خطا، ۱۹ درصد میانگین قدرمطلق خطا و ۵ درصد میانگین درصد قدرمطلق خطا، این روش به عنوان الگوی پیش‌بینی انتخاب گردید و برای تمامی ماه‌های سال ۲۰۱۲ پیش‌بینی انجام گرفت و روند تقاضای جهانی برای نفت اوپک تا سال ۲۰۱۵ برآورد گردید. براساس تخمین‌های صورت گرفته، پیش‌بینی می‌شود که تقاضا برای نفت اوپک تا سال ۲۰۱۵ صعودی باشد ولی سرعت افزایشی بودن آن از سال ۲۰۱۴ کندتر خواهد شد. به علاوه نتایج بیانگر آن است که در بلندمدت رابطه منفی بین قیمت جهانی نفت و تقاضا برای نفت اوپک وجود دارد و همچنین زمانی که تولید جهانی افزایش می‌یابد، باعث می‌شود تقاضای جهانی نفت و در نتیجه تقاضا برای نفت اوپک نیز افزایش یابد.

منابع**الف - فارسی**

- ابریشمی، حمید، و همکاران (۱۳۸۹)، «پیش‌بینی قیمت گازوئیل خلیج فارس مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی»، فصلنامه مطالعات اقتصاد انرژی، مؤسسه مطالعات بین‌المللی انرژی، شماره ۲۴.
- آقایی، کیومرث و بهروز پورمیری (۱۳۸۵)، «پیش‌بینی روند قیمت فولاد با استفاده از شبکه عصبی مصنوعی و مقایسه نتایج با روش ARIMA»، فصلنامه بررسی‌های اقتصادی، دوره ۳، شماره ۱.

مقایسه توانایی پیش‌بینی مدل‌های VAR، ARIMA و شبکه‌های ... ۱۶۷

بغزیان، آلبرت و ابراهیم نصرآبادی (۱۳۸۵)، «پیش‌بینی مصرف فرآورده‌های نفتی: مقایسه سیستم معادلات اقتصادسنجی و شبکه عصبی»، فصلنامه مطالعات اقتصاد انرژی، سال سوم، شماره ۱۰، صص ۶۷-۴۷.

خاموشپور، بهنام (۱۳۸۹)، «ارائه مدلی ترکیبی از شبکه‌های عصبی جهت پیش‌بینی شاخص بورس اوراق بهادار تهران»، چهارمین کنفرانس داده‌کاوی ایران، دانشگاه صنعتی شریف.

مشیری، سعید و فائزه فروتن (۱۳۸۳)، «آزمون آشوب و پیش‌بینی قیمت‌های آتی نفت خام»، فصلنامه پژوهش‌های اقتصادی ایران، شماره ۲۱، صص ۹۰-۶۷.

مهرآرا، محسن، و همکاران (۱۳۸۹)، «پیش‌بینی بی‌ثباتی قیمت نفت با استفاده از شبکه عصبی GMDH»، فصلنامه مطالعات اقتصاد انرژی، مؤسسه مطالعات بین‌المللی انرژی، شماره ۲۵.

مهرآرا، محسن، و همکاران (۱۳۸۹)، «امکان افزایش عایدی حاصل از ناکارایی‌ها در بازار آتی نفت خام»، پژوهش‌نامه اقتصادی، پژوهشکده امور اقتصادی، شماره ۷، ویژه‌نامه بازار سرمایه.

ب- انگلیسی

Church, K. B. and S. P. Curram (1996), "Forecasting Consumers' Expenditure: A Comparison between Econometric and Neural Network Models", *International Journal of Forecasting*, Vol. 12, pp. 255-267.

Fu, J. (1998), "A Neural Network Forecast of Economic Growth and Recession", *The Journal of Economics*, Vol. XXIV, No. 1, pp. 51-66.

Heravi, S., Osborn, D. R. and C. R. Birchenhall (2004), "Linear Versus Neural Network Forecasts for European Industrial Production Series", *International Journal of Forecasting*, Vol. 20, pp. 435-446.

Hill, T., et al (1994), "Artificial Neural Network Models for Forecasting and Decision Making", *International Journal of Forecasting*, Vol. 10, pp. 5-15.

Hwang, H. Brian, H. T. Ang (2001), "A Simple Neural Network for ARMA (p,q) Time Series", *Omega*, Vol. 29, pp. 319-333.

Kohzadi, N., Boy, M. S. and I. Kaastra (1996), "Neural Networks for Forecasting: An Introduction", *Canadian Journal of Agricultural Economics*, Vol. 43, pp. 463-474.

Longo, C., et al (2007), "Evaluating the Empirical Performance of Alternative Econometric Models for Oil Price Forecasting", Working Paper of International Energy Markets.

Moshiri, S. and N. E. Cameron (2000), "Neural Network Versus Econometric Models in Forecasting Inflation", *Journal of Forecasting*, Vol. 19, pp. 201-217.

- Olson, D. and C. Mossman (2003), "Neural Networks of Canadian Stock Returns Using Accounting Ratios", *International Journal of Forecasting*, Vol. 19, pp. 453-465.
- Portugal, N. S. (1995), "Neural Networks Versus Time Series Methods: A Forecasting Exercises", 14th International Symposium on Forecasting, Sweden.
- Qi, M. (2001), "Predicting US Recessions with Leading Indicators Via Neural Network Models", *International Journal of Forecasting*, Vol. 17, No. 3, pp. 383-401.
- Tkacz, G. (2001), "Neural Network Forecasting of Canadian GDP Growth", *International Journal of Forecasting*, Vol. 17, pp. 57-69.
- White, H. (1993), "Economic Prediction Using Neural Networks: The Case of IBM Daily Stock Returns", <http://www.citeseer.nj.nec.com/context>.
- Wu, SH. I. and R. P. Lu (1993), "Combining Artificial Neural Networks and Statistics for Stock-market Forecasting", pp. 257-264.
- Zhang, G., *et al* (1999), "Artificial Neural Network in Bankruptcy Prediction: General Framework and Cross Validation Analysis", *European Journal of Operational Research*, Vol. 116, No. 1, pp. 16-32.