

پیش‌بینی عرضه نفت خام در یازده کشور تولیدکننده با استفاده از شبکه‌های عصبی و رگرسیون خطی (۲۰۰۶-۱۹۸۰)

علیرضا شکیبایی*

استادیار گروه اقتصاد دانشگاه شهید باهنر کرمان

حسین نظام آبادی پور

دانشیار گروه مهندسی برق دانشگاه شهید باهنر کرمان

سید جعفر حسینی

دانشجوی کارشناسی ارشد اقتصاد دانشگاه شهید باهنر کرمان

چکیده

اغلب مدل‌های انحصار چندجانبه بازار نفت، با فرض وجود کارتلی به نام اوپک شروع می‌شوند. افزایش پی در پی قیمت‌های نفت در طی سال‌های اخیر و عدم توانایی اوپک در تنظیم بازار، امکان وجود رفتار رقابتی در بازار نفت را شدت می‌بخشد. حال با توجه به این نوسانات شدید در بازار نفت، پیش‌بینی عرضه نفت، برای سیاست‌گذاران و شرکت‌های نفتی بسیار حایز اهمیت می‌باشد. در سال‌های اخیر استفاده از شبکه‌های عصبی مصنوعی در کنار روش‌های اقتصادسنجی در پیش‌بینی متغیرهای مهم اقتصادی مرسوم شده است. علت آن نیز در ویژگی‌های منحصر به فرد شبکه‌های عصبی از قبیل: آزادی از فرضیه‌های آماری و قابلیت حل مسائل غیرخطی پیچیده می‌باشد. در این مقاله سعی شده است علاوه بر پیش‌بینی تولید نفت خام در یازده کشور تولیدکننده، با استفاده از دو مدل رگرسیون خطی و شبکه‌های عصبی، نتایج به دست آمده در هر کشور به طور مجزا مقایسه شود. تخمین‌ها، حاکی از آن است که شبکه‌های عصبی پیش‌بینی‌های بهتری نسبت به مدل‌های رگرسیون خطی ارائه می‌کنند.

واژه‌های کلیدی: شبکه‌های عصبی، پیش‌بینی، عرضه نفت خام

طبقه بندی JEL: C63, C6, Q4, Q47

Prediction Crude Oil Supply in the Eleven Producing Countries: Use of Neural Networks and Linear Regression (1980-2006)

Alireza Shakibayee

*Assistance Professor in economics,
University of Shahid Bahonar, Kerman*

Hossein Nezamabadi-pour

*Associate Professor of Electrical
Engineering, University of Shahid
Bahonar, Kerman*

Seyed Jafar Hosseini

*Student of M.Sc in Economics,
University of Shahid Bahonar, Kerman*

Abstract

Most oligopolistic models in the oil market begin with the assumption that OPEC is a cartel. Successive increases in oil prices during recent years, and OPEC's inability to regularize the oil market fortifies the possibility of the existence of competitive behavior in the oil market. Now, with regard to the intense fluctuations in the oil market, prediction of oil supply for politicians and oil companies is important. In the recent years, use of neural networks, along with econometrical methods, of forecasting of economic variables is a norm. Because neural networks have, exclusive characteristics like release of statistical hypotheses and capability of solving complex nonlinear problems. In this article in addition to prediction oil supply in the eleven producing countries, by use of linear regression and neural networks, the results of every country are separately compared. The estimation results show that neural networks are presenting better predictions in comparison to the linear regression models.

Key words: neural networks, prediction, oil supply

JEL: C6, C63, Q4, Q4

مقدمه

کارشناسان نفتی همواره به دنبال راهی ساده اما مطمئن جهت پیش‌بینی تولید نفت خام بوده‌اند. پیش‌بینی عرضه نفت خام به سیاستگذاران توانایی تحلیل‌های اقتصادی در شرایط مختلف و به مهندسان قابلیت تخمین تغییرات ذخایر نفتی و تأثیر آن بر قیمت‌های آینده نفت را ارائه می‌دهد.

در این میان، طی سال‌های اخیر شبکه‌های عصبی مصنوعی پیشرفت قابل توجهی در ارایه پیش‌بینی‌های مطلوب خصوصاً در مورد داده‌هایی که آشفتگی زیادی دارند، داشته‌اند. از جمله مهم‌ترین داده‌های با نوسان زیاد، اطلاعات بازار نفت می‌باشد، که هم از بعد قیمت و هم از بعد عرضه دچار آشفتگی فراوان هستند.

شبکه‌های عصبی مصنوعی که با بهره‌گیری از شبکه عصبی طبیعی انسان طراحی شده‌اند از جمله نظام‌های هوش مصنوعی هستند که قادرند با آموزش دیدن، داده‌هایی را که تا به حال ندیده‌اند پیش‌بینی یا طبقه‌بندی کنند. از خصوصیات بارز آنها این است که سرعت محاسبات را نسبت به سایر روش‌های پیش‌بینی به طور قابل توجهی افزایش می‌دهند و خطای حاصل از پیش‌بینی را نیز کاهش می‌دهند. بسیاری از اقتصاددانان به علت آزاد بودن شبکه‌های عصبی از مفروضات آماری بر آنها خرده می‌گیرند و مدعی هستند که شبکه‌ها با بی‌توجهی به تئوری‌ها، همانند یک جعبه سیاه که هیچ‌گونه اطلاعی از کم و کیف و فعل و انفعالات درونی آن در دست نیست، می‌باشند. (Moshiri, 2001) کان و وایت (Kaun & White, 1994) برای حل این مسئله سعی کردند رابطه‌ای میان تئوری‌های آماری و اقتصادسنجی با شبکه‌های عصبی بیابند. مشیری و کامرون (Moshiri & Cameron, 2000) نیز به این نتیجه رسیده‌اند که بدون استفاده از تئوری‌های اقتصادی نمی‌توان نتایج خوبی در پیش‌بینی به دست آورد.

در این مقاله نیز برای آنکه پیش‌بینی خوبی از داده‌ها انجام شود و صرفاً با بی‌اعتنایی به تئوری‌های اقتصادی با ورود یک سری اطلاعات مربوط به قیمت نفت، یک سری خروجی تحت عنوان عرضه نفت پدیدار نشود، از تئوری اقتصادی استفاده شده است و چنانچه تئوری مورد نظر در مورد عرضه نفت خام یک کشور با توجه به داده‌های موجود مورد تأیید قرار گرفت، آنگاه مقایسه پیش‌بینی از دو مدل رگرسیون خطی و شبکه‌های عصبی برای هر کشور انجام شده است.

پیشینه تحقیق

نوسانات شدید در عرضه و قیمت نفت خام همواره تئوری‌های موجود در این بخش را دچار تردید می‌کند. روند صعودی قیمت‌های نفت خام و عدم توانایی اوپک به عنوان تنها انحصارگر نفتی در کنترل آن، علیرغم افزایش تولید، فرض رقابتی بودن بازار نفت خام را تقویت می‌کند. ابتدا عزتی (Ezzati, 1976) این فرضیه را مطرح کرد که کشورهای صادرکننده نفت خام به علت

ظرفیت‌های محدود جذب ارز خارجی برای سرمایه‌گذاری‌های داخلی، ابتدای هر سال سقف معینی از سرمایه‌گذاری را برای خود تعریف می‌کنند. حال اگر با افزایش قیمت‌های نفت خام، درآمدهای ارزی از حد معین شده تجاوز کرد، تولید خود را کاهش می‌دهند. بنابراین به یک منحنی عرضه برگشت‌پذیر می‌رسیم (مدل TRT)^۱. بعد از آن کرومر و اصفهانی (Isfahani, 1980) و Cremer & Teece (1982)، تیس (Teece, 1982) و رمچارن (Ramcharron, 2001) سعی کردند این مدل را با داده‌های جدیدتر و فرضیات بیشتر آزمون کرده و گسترش دهند. از طرف دیگر مک آوی (Mac Avoy, 1982) این نظریه را بیان کرد که نوسانات قیمت‌های نفت خام را می‌توان با یک مدل مبتنی بر نظام بازار (عرضه صعودی و تقاضای نزولی) بهتر از سایر روش‌ها توضیح داد. Griffen (1985) با بررسی چهار مدل الف) عرضه رقابتی ب) عرضه مبتنی بر TRT ج) عرضه به صورت انحصاری د) عرضه بر اساس تئوری حق مالکیت، به این نتیجه رسید که مدل رقابتی در بین مجموع کشورهای صادرکننده نفتی، نتایج بهتری را ارائه می‌کند. زیرا که تئوری به کار گرفته شده علیرغم سادگی، توانایی توضیح نوسانات بازار نفت را در شرایطی که منحنی عرضه صعودی نیست دارا می‌باشد.

کاربرد شبکه‌های عصبی در اقتصاد نیز، ابتدا در بازارهای مالی شروع شد. از جمله این پژوهش‌ها، می‌توان به کارهای وانگ (Wong, 1990) بوزارج (Bosarge, 1992) و ریفسنس (Refenes, 1995) اشاره کرد. بعد از دهه ۱۹۹۰ میلادی متخصصان سایر بخش‌های اقتصادی که پی به عملکرد مطلوب‌تر این مدل‌ها نسبت به مدل‌های رایج اقتصادسنجی در پیش‌بینی متغیرهای اقتصادی برده بودند، سعی در بسط و گسترش این مدل‌ها در قسمت‌های مختلف علم اقتصاد کردند. از مهم‌ترین آنها می‌توان به مقاله کان و وایت (Kaun & White, 1994) اشاره کرد. در تحقیق مورد نظر بسیاری از روابط موجود در شبکه‌های عصبی با روابط موجود در اقتصادسنجی وفق داده شده است. بعد از آن معصومی، ختن‌زاد و عبایی (Maasoumi, Khotanzad & Abaye, 1994)، به پیش‌بینی برخی متغیرهای اقتصادی آمریکا همانند شاخص قیمت مصرف‌کننده، تولید ناخالص ملی و دستمزدها پرداخته‌اند. مشیری و براون (Moshiri & Brown, 2003) در تحقیقی

با استفاده از دو شبکه عصبی^۱ (MLP) و^۲ (GRNN) به پیش‌بینی نرخ بیکاری در پنج کشور صنعتی آمریکا، ژاپن، انگلستان، کانادا و فرانسه پرداخته‌اند و با استفاده از معیار درصد میانگین مربعات خطا^۳ نتیجه گرفته‌اند که مدل‌های خطی در پیش‌بینی کارایی ندارند و مدل‌های غیرخطی نیز توانایی کمتری نسبت به شبکه‌های عصبی در پیش‌بینی دارند.

اینس و ترافالیس (Ince & Trafalis, 2006) به پیش‌بینی نرخ ارز با استفاده از یک روش ترکیبی^۴ متشکل از روش‌های اقتصادسنجی و شبکه‌های عصبی پرداخته‌اند. بر این اساس آنها ابتدا با استفاده از روش‌های اقتصادسنجی سعی در شناخت خواص آماری داده‌ها و انتخاب داده‌های مناسب برای پیش‌بینی کرده‌اند. سپس با استفاده از شبکه‌های عصبی به پیش‌بینی داده‌های گزینش شده مبادرت کرده‌اند. نتایج حاکی از آن است که ابزار SVR^۵ در ترکیب با هر نوع از روش‌های انتخاب داده‌ها، به دلیل ساختار موجود در آن، جواب‌های بهتری نسبت به شبکه^۶ MLP از خود نشان می‌دهد. در خاتمه نیز محققان از دو روش میانگین متحرک انباشته خودهمبسته^۷ و خودرگرسیون برداری^۸ به تنهایی برای پیش‌بینی نرخ ارز استفاده کرده‌اند که جواب‌های آنها نسبت به شبکه‌های عصبی بسیار ضعیف‌تر بوده است. ناصرالدین و ملک (Nasereddin & Malik, 2006) در بررسی بازار نفت به این نتیجه رسیده‌اند که قیمت‌ها در بازار نفت یک روند غیر خطی را دارا می‌باشند. آنها در تحقیق خود سعی کرده‌اند با استفاده از قیمت‌های نفت، تولید ناخالص داخلی را در آمریکا پیش‌بینی کنند. پیش‌بینی مورد نظر از روش‌های گام تصادفی^۹، اتورگرسیون^{۱۰}، رگرسیون خطی و شبکه‌های عصبی استفاده کرده است و دو معیار میانگین قدرمطلق خطا^{۱۱}

-
- 1- Multi Layer Perceptron
 - 2- Generalized Regression Neural Network
 - 3- Mean Squared Percentage Error
 - 4- Hybrid Method
 - 5- Support Vector Regressive
 - 6- Multi layer Perceptron
 - 7- Autoregressive Integration Moving Average
 - 8- Vector Autoregression
 - 9- Random Walk
 - 10- Autoregressive
 - 11- Mean Absolute Error

(MAE) و میانگین مربعات خطا^۱ (MSE) برای مقایسه به کار رفته است. نتایج حاکی از آن است که شبکه‌های عصبی نتایج بهتری در پیش‌بینی ارائه می‌کنند.

در ایران نیز طی سال‌های اخیر، اقتصاددانان سعی کرده‌اند بسیاری از متغیرهای اقتصادی را با استفاده از شبکه‌های عصبی پیش‌بینی کنند. از نخستین کارها می‌توان به تحقیق مشیری (2001, Moshiri) که در ارتباط با پیش‌بینی تورم در ایران با سه روش مدل‌های ساختاری، سری زمانی و شبکه‌های عصبی می‌باشد، اشاره کرد. وی در این تحقیق ریشه میانگین مربعات خطا^۲ (RMSE)، (MAE) و آماره^۳ U تایل را برای مقایسه نتایج خود به کار برده است و به خطای کمتر و نتایج بهتر شبکه‌های عصبی در پیش‌بینی پی برده است. فلاحی و دیگران (Falahi & others, 2005) در الگوسازی و پیش‌بینی درآمدهای مالیات بر مشاغل در ایران به بررسی کاربرد شبکه‌های عصبی و مقایسه آن با الگوهای رگرسیون خطی و سری زمانی پرداخته‌اند. در این مقاله آنها از یک شبکه دو لایه پیش‌خور و الگوریتم آموزشی پس انتشار خطا استفاده کرده‌اند. محققان با استفاده از معیارهای RMSE و MAE به این نتیجه رسیده‌اند که شبکه‌های عصبی پیش‌بینی بهتری از درآمدهای مالیات بر مشاغل نسبت به دو مدل دیگر از خود نشان می‌دهند.

مرزبان و همکاران (Marzban & assistances, 2005) در تحقیقی به مقایسه بین مدل‌های اقتصادسنجی ساختاری، سری زمانی و شبکه‌های عصبی مصنوعی برای پیش‌بینی نرخ ارز پرداخته‌اند. در این تحقیق، شبکه‌های عصبی مصنوعی و برخی الگوهای متداول اقتصادسنجی در زمینه پیش‌بینی نرخ ارز اسمی ایران مورد آزمون و مقایسه قرار گرفته‌اند. نتایج حاکی از آن است که عملکرد شبکه‌های عصبی در حالت کلی بر تمامی مدل‌ها، برتری دارد و الگوهای سری زمانی، اندکی از الگوهای ساختاری بهتر عمل می‌کنند. احمدی (Ahmadi, 2006) به مقایسه روش‌های مختلف پیش‌بینی سری زمانی با استفاده از داده‌های نرخ ارز به وسیله سه ابزار مختلف شبکه‌های عصبی، تبدیل موجک^۴ و فرآیند میانگین متحرک انباشته خود همبسته پرداخته است. او در این تحقیق نتیجه گرفته است که در پیش‌بینی‌های یک گام به جلو و شش گام به جلو تا ده گام به جلو،

1- Mean Squared Error

2- Root Mean Squared Error

3- U Theil

4- Wavelet

مدل شبکه‌های عصبی از سایر مدل‌ها بهتر عمل می‌کند. اما در پیش‌بینی‌های دو گام به جلو تا پنج گام به جلو، مدل شبکه‌های عصبی و مدل موجک تفاوت چندانی از یکدیگر نداشته و هر دو مدل بهتر از مدل اقتصادسنجی جواب می‌دهند.

نیل ساز (Nilsaz, 2006) در تحقیقی به استفاده از شبکه‌های عصبی و کاربرد آن در رتبه‌بندی اعتبار متقاضیان دریافت وام پرداخته است. در این تحقیق کارایی مدل شبکه‌های عصبی برای شناسایی مشتریان مشکل‌دار بررسی شده است و دقت این مدل در برابر سایر مدل‌های آماری و اقتصادی مورد ارزیابی قرار گرفته است. نتایج تحقیق نشان می‌دهد شبکه عصبی مورد استفاده به طور معنی‌داری در شناسایی متقاضیان دریافت وام، عملکرد بهتری از خود نشان می‌دهد و با مقایسه آن با سایر تکنیک‌های رتبه‌بندی می‌توان گفت که شبکه‌های عصبی جایگزین مناسب برای سایر تکنیک‌های طبقه‌بندی است.

مدل

با توجه به مباحث مطرح شده در پیشینه تحقیق، در این مطالعه نیز مدل رقابتی ارائه شده توسط گریفن مبنای تئوریک مسئله می‌باشد (رابطه ۱).

$$\ln Q = \alpha + \beta \ln p + \varepsilon \quad (1)$$

Q = تولید نفت خام (بشکه در روز/۱۰۰۰)


P = قیمت نفت خام نسبت به شاخص کل کالاها و خدمات

ε = خطای حاصل از تخمین رگرسیون

α = عرض از مبدأ

β = کشش قیمتی عرضه نفت خام

اگر β از لحاظ آماری مثبت و معنی‌دار باشد عرضه نفت آن کشور از عرضه سعودی پیروی می‌کند و اگر β از لحاظ آماری منفی و معنی‌دار باشد عرضه نفت در آن کشور به صورت عرضه برگشت پذیر می‌باشد.



شکل ۱ - منحنی عرضه برگشت‌پذیر

p_1 : قیمت تعادلی

p_2 : سطحی از قیمت، که در آن درآمد هدف اتفاق می‌افتد.

تا قبل از شکل‌گیری تئوری (TRT) تصور می‌شد که منحنی عرضه نفت به طور معمول AC می‌باشد و در سطح نقطه C اوپک با جذب مازاد عرضه به مقدار BC از کاهش قیمت‌های نفت جلوگیری می‌کند. اما بعد از شکل‌گیری تئوری مورد نظر، معلوم شد که شکل منحنی عرضه به صورت AB می‌باشد و نقطه B یک نقطه تعادلی بوده و اوپک نقشی به عنوان یک کارتل در به دست آمدن این سطح تعادلی نداشته است.

داده‌های مورد استفاده در این تحقیق، داده‌های ماهانه تولید و قیمت نفت خام می‌باشد. دوره مورد بررسی نیز بین سال‌های (۲۰۰۶-۱۹۸۰) می‌باشد. قیمت‌های نفت خام در هر کشور به طور نسبی بیان شده است به این معنا که قیمت نفت خام بر شاخص خدمات و کالاهای مصرفی^۱ (CPI) تقسیم شده است. به علت محدودیت دسترسی به اطلاعات تمام کشورهای تولیدکننده نفت، یازده کشور که اطلاعات آنها به طور کامل در دسترس بوده است، انتخاب شده‌اند. از میان این کشورها، پنج کشور: الجزایر، ایران، قطر، عربستان سعودی و نیجریه از اعضای اوپک بوده و شش کشور: نروژ، آمریکا، انگلستان، مکزیک، مصر و روسیه از اعضای غیر اوپک می‌باشند. اطلاعات مربوط به

1- Consumer Price Index

قیمت‌ها و تولیدات نفت خام هر کشور از سایت اداره مرکزی انرژی امریکا و از بخش (Monthly Energy Review) و اطلاعات مربوط به شاخص قیمت‌ها در هر کشور از آمارنامه‌های سالیانه صندوق بین‌المللی پول^۱ جمع‌آوری شده است. سال پایه بر اساس نظر صندوق بین‌المللی پول برای همه کشورها سال ۱۹۹۵ میلادی انتخاب شده است.

از بین داده‌های موجود، اطلاعات مربوط به سال‌های (۱۹۸۰-۲۰۰۱) برای آزمون معناداری تئوری برای هر کشور انتخاب شده است. چنانچه تئوری مذکور در کشوری از لحاظ آماری معنادار بود، از داده‌های سال‌های (۲۰۰۲-۲۰۰۶) برای پیش‌بینی استفاده شده است. در آموزش شبکه‌های عصبی نیز داده‌های سال‌های (۱۹۸۰-۲۰۰۱) به کار برده شده است. همچنین مدل شبکه عصبی با کمک نرم‌افزار MATLAB^۲ برآورد شده است. جهت بررسی و مقایسه نتایج حاصل از پیش‌بینی با دو مدل رگرسیون خطی و شبکه عصبی، از دو معیار زیر استفاده شده است.

$$\text{RMSE} = \frac{\sqrt{\sum (\hat{y}_i - y_i)^2}}{n} \quad (2)$$

$$= \frac{\sum |\hat{y}_i - y_i|}{n} \text{MAE} \quad (3)$$

در خاتمه نیز برای اینکه متوجه بشویم آیا نتایج حاصل از پیش‌بینی از لحاظ آماری نیز تفاوت معنی‌داری دارند یا خیر، از آزمون میانگین تفاضل زیان^۲ استفاده شده است. (Moshiri, 2001) در این روش ابتدا متغیر تفاضل زیان نمونه به صورت زیر محاسبه شده است:

$$d_t = I(e_{t+h,t}^a) - I(e_{t+h,t}^b) \quad (4)$$

$I(e_{t+h,t})$ بیانگر تابع زیان که بر اساس مقداری خطای پیش‌بینی (e) تعریف شده است، می‌باشد. h افق پیش‌بینی، a و b نیز روش‌های پیش‌بینی را نشان می‌دهند. در مرحله بعد، رگرسیونی متشکل از متغیر d_t به عنوان متغیر وابسته و c به عنوان عرض از مبدأ (عدد ثابت) اجرا می‌شود. اگر عدد ثابت از لحاظ آماری معنی‌دار بود، معنی‌دار بودن اختلاف بین دو تابع زیان به دست آمده از دو مدل a و b را نتیجه می‌دهد. در غیر اینصورت نمی‌توان اختلاف ظاهری بین دو تابع را معنی‌دار

1- International Financial Statistics Year Book

2- Mean Loss Differential

تلقی کرد. به عبارت دیگر نمی‌توان یک مدل را بر مدل دیگر برتر دانست.

نتایج برازش مدل و پیش‌بینی

ابتدا در جدول شماره (۱) نتایج حاصل از تخمین رگرسیون در یازده کشور به طور مجزا برای داده‌های سال‌های (۲۰۰۱-۱۹۸۰) آورده شده است. همان‌طور که نتایج جدول (۱) نشان می‌دهد تئوری مورد نظر در مورد کشور عربستان تأیید نمی‌شود که این سازگار با تحقیقات گذشته می‌باشد (Ramcharran, 2002) در مورد سایر کشورهای عضو اوپک تئوری عرضه برگشت‌پذیر صدق می‌کند. سپس بجز کشور عربستان در ده کشور باقی مانده به پیش‌بینی قیمت‌های نفت آنها در فاصله سال‌های (۲۰۰۶-۲۰۰۲) پرداخته شده است و نتایج آن در جدول شماره (۳) آورده شده است. البته ابتدا نتایج آموزش شبکه‌های عصبی در جدول شماره (۲) بررسی شده است.

هر چه مقدار RMSE و MAE در مدلی کمتر باشد نشان دهنده بهتر بودن نتایج پیش‌بینی در آن مدل می‌باشد. در انتها نیز برای آنکه اطمینان بیشتری نسبت به نتایج به دست آمده حاصل شود و متوجه شویم که تفاوت در پیش‌بینی‌های حاصل از دو مدل ناشی از خطاهای نمونه‌ای است یا از لحاظ آماری نیز تفاوت معنی‌داری بین این نتایج مشاهده می‌شود، از آزمون میانگین تفاضل زیان که فروض آن به صورت زیر می‌باشد استفاده شده است و نتایج آن در جدول (۴) گزارش شده است.

دو نتیجه حاصل از پیش‌بینی‌ها در دو مدل تفاوت معنی‌داری ندارند: H_0

نتایج حاصل از پیش‌بینی‌ها در دو مدل تفاوت معنی‌داری دارند: H_1

جدول (۱) نتایج حاصل از تخمین مدل گریفن برای کشورهای نفتی (۱۹۸۰-۲۰۰۱)

F	R^2	LNP	ضریب ثابت	کشور
۳۰۱/۷۷	۰/۵۳	-۰/۰۷۴** (۰/۰۰۴۲) ^۱	۶/۹۸	الجزایر
۵۰۱/۹	۰/۶۵	-۰/۱۹۱** (۰/۰۰۸۵)	۷/۸۱	ایران
۰/۶۸۶	۰/۰۰۲۶	-۰/۰۴۷ (۰/۰۰۵۷۰)	۸/۷۴	عربستان
۲۸/۲۳	۰/۰۹۷	-۰/۲۱۸** (۰/۰۰۴۱۰)	۵/۷۳	قطر
۲۲۵/۲۴	۰/۴۶	-۰/۰۸۹** (۰/۰۰۵۹)	۷/۴۷	نیجریه
۲۲۶/۴۶	۰/۴۶	۰/۲۱۶** (۰/۰۰۱۴۰)	۹/۲	آمریکا
۳/۵۵	۰/۰۱۴	-۰/۰۴۱* (۰/۰۰۲۲)	۷/۶۵	انگلستان ^۲
۷۷/۹۹	۰/۳۹	۰/۰۲۸** (۰/۰۰۳۲)	۸/۷۹	روسیه ^۳
۱۹۵/۱۱	۰/۴۲	-۰/۰۷۹** (۰/۰۰۵۰)	۶/۶۲	مصر
۱۴۰/۴۷	۰/۳۴	-۰/۰۲۷** (۰/۰۰۲۳)	۷/۸۸	مکزیک
۵۱۷/۹۵	۰/۶۶	-۱/۰۳** (۰/۰۰۴۵۰)	۵/۹	نروژ

منبع: محاسبات تحقیق

۱- اعداد داخل پرانتز نشان دهنده انحراف معیار می باشد.

۲- داده‌های انگلستان از سال ۱۹۸۲ به بعد می باشد

۳- داده‌های روسیه از سال ۱۹۹۲ به بعد می باشد

** سطح معنی‌داری ۰/۰۵

* سطح معنی‌داری ۰/۱

ضرایب به وسیله نرم افزار eviews۵ برآورد شده است.

جدول (۲) نتایج آموزش شبکه‌های عصبی (۲۰۰۱-۱۹۸۰)

کشور	تعداد نرون‌های لایه میانی	سطح حداقلی خطا	RMSE
الجزایر	۳	10^{-4}	۰/۰۰۸۴
ایران	۲	10^{-3}	۰/۰۳۱۱
قطر	۴	10^{-3}	۰/۰۳۰۷
نیجریه	۵	10^{-3}	۰/۰۱۶۴
آمریکا	۴	10^{-3}	۰/۰۱۱۳
انگلستان	۲	10^{-3}	۰/۰۳۱۰
روسیه	۸	10^{-4}	۰/۰۰۶۷
مصر	۲	10^{-4}	۰/۰۰۹۳
مکزیک	۶	10^{-4}	۰/۰۰۵۸
نروژ	۲	10^{-2}	۰/۰۸۶۴

منبع: محاسبات تحقیق

جدول (۳) مقایسه نتایج پیش‌بینی از دو مدل شبکه عصبی و رگرسیون (۲۰۰۶-۲۰۰۲)

کشور	رگرسیون	RMSE	رگرسیون	MAE	شبکه عصبی
الجزایر	۰/۰۶۹۹	۰/۰۳۲۲	۰/۰۵۶۰	۰/۰۲۹۲	شبکه عصبی
ایران	۰/۰۴۹۱	۰/۰۳۱۹	۰/۰۴۰۴	۰/۰۳۱۱	شبکه عصبی
قطر	۰/۰۳۷۸	۰/۰۵۷۶	۰/۰۳۲۱	۰/۰۵۶۱	شبکه عصبی
نیجریه	۰/۰۶۱۳	۰/۰۱۳۶	۰/۰۵۴۶	۰/۰۱۱۸	شبکه عصبی
آمریکا	۰/۰۳۹۸	۰/۰۳۵۰	۰/۰۲۷۱	۰/۰۳۱۴	شبکه عصبی
انگلستان	۰/۰۶۹۳	۰/۰۱۰۰	۰/۰۵۸۰	۰/۰۰۸۰	شبکه عصبی
روسیه	۰/۰۵۱۴	۰/۰۳۰۱	۰/۰۴۳۶	۰/۰۲۹۱	شبکه عصبی
مصر	۰/۰۲۷۶	۰/۰۱۹۴	۰/۰۳۲۱	۰/۰۵۶۱	شبکه عصبی
مکزیک	۰/۰۳۳۶	۰/۰۱۴۵	۰/۰۲۷۸	۰/۰۱۳۷	شبکه عصبی
نروژ	۰/۰۴۸۷	۰/۰۶۳۰	۰/۰۴۱۱	۰/۰۶۱۶	شبکه عصبی

منبع: محاسبات تحقیق

جدول (۴) مقایسه آماری نتایج حاصل از پیش‌بینی

کشور	t محاسبه شده (انحراف معیار)	c	P-value
الجزایر	۳/۴۶۸** (۰/۰۰۸۳)	۰/۰۲۹	۰/۰۰۱
ایران	۵/۳۷۶** (-۰/۰۰۵۷)	۰/۰۳۱۱	۰/۰۰
قطر	۱۱/۹۵۹** (۰/۰۰۴۶)	۰/۰۵۶	۰/۰۰
نیجریه	۱/۶۱۸ (۰/۰۰۷۲)	۰/۰۱۱	۰/۱۱
آمریکا	-۶/۲۸۸** (۰/۰۰۴۹)	-۰/۰۳۱	۰/۰۰
انگلستان	-۰/۱۸۹ (۰/۰۰۸۳)	-۰/۰۰۱۵	۰/۸۵
روسیه	۴/۷۴۴** (۰/۰۰۶۱)	۰/۰۲۹	۰/۰۰
مصر	-۵/۸۶۵** (۰/۰۰۳۲)	-۰/۰۱۹	۰/۰۰
مکزیک	۳/۴۱۷** (۰/۰۰۴۰)	۰/۰۱۳	۰/۰۰۱۲
نروژ	۱۰/۳۴۸** (۰/۰۰۵۹)	۰/۰۶۱	۰/۰۰

منبع: محاسبات تحقیق

** سطح معنی‌داری ۰/۰۵

نتیجه‌گیری

تئوری عرضه رقابتی، توانایی توضیح تغییرات عرضه کشورهای صادرکننده نفت را در پاسخ به تغییرات قیمتی دارد. از آنجا که این تئوری عموماً در مورد کشورهای در حال توسعه صادرکننده نفت منحنی عرضه برگشت‌پذیر را نشان می‌دهد، می‌توان صحت تئوری درآمد هدف یا محدود بودن سقف درآمدهای ارزی را در مورد این کشورها نتیجه‌گیری کرد. همان‌طور که نتایج جدول

(۱) نشان می‌دهد تئوری مورد نظر صرفاً در مورد کشور عربستان تأیید نمی‌شود. اما در مورد سایر کشورهای عضو اوپک تئوری عرضه برگشت‌پذیر صدق می‌کند. اما نظریه TRT توانایی توجیه تغییرات عرضه در کشورهای صنعتی را ندارد در حالی که تئوری رقابتی گریفن با نشان دادن عرضه سعودی در کشورهای صنعتی عرضه‌کننده نفت خام، نشان می‌دهد که محدودیت ارزی با توجه به بازارهای مالی توسعه یافته در این کشورها وجود ندارد. تحقیقات گذشته در مورد تئوری عرضه رقابتی نیز عموماً نشان‌دهنده این بوده است که در کشورهای عضو اوپک مدل تأیید می‌شود. تنها تفاوت چشمگیر بین تحقیقات، تأیید تئوری در کشورهای غیر اوپک می‌باشد که در این تحقیق نیز مشاهده می‌شود. به طور مثال گریفن (Griffin, 1985) در پژوهش خود به این نتیجه رسید که مدل عرضه رقابتی برای کشورهای مصر، مکزیک، نروژ، انگلستان و روسیه تأیید می‌شود و صرفاً عرضه نفت آمریکا به صورت برگشت‌پذیر می‌باشد در حالی که رمچارن (Ramcharron, 2001) در تحقیق خود نتایجی حاصل از مثبت بودن کشش عرضه برای کشورهای مکزیک، نروژ، مصر، آمریکا و انگلستان را به دست می‌آورد و برای روسیه عرضه برگشت‌پذیر را تأیید می‌کند. همان‌طور که رمچارن نیز بیان می‌کند علت اصلی این تفاوت‌ها را باید در تغییر دوره مورد بررسی دانست زیرا در هر دوره شرایط بازار نفت به طور چشمگیری تغییر می‌کند. در این تحقیق نیز عرضه آمریکا و روسیه به صورت عرضه رقابتی می‌باشد و تأیید مدل برای کشور انگلستان نیز به سختی انجام می‌شود. علیرغم دو پژوهش مهم قبلی، عرضه نفت در کشورهای نروژ، مکزیک و مصر به صورت برگشت‌پذیر می‌باشد.

در مقایسه بین نتایج پیش‌بینی مدل شبکه‌های عصبی و رگرسیون خطی در مورد معیار RMSE در تمامی موارد بجز کشور قطر شبکه‌های عصبی پیش‌بینی بهتری از خود نشان می‌دهند. در مورد چهار کشور نروژ، مصر، آمریکا و قطر، MAE کمتری در مدل رگرسیون نسبت به شبکه‌های عصبی دیده می‌شود. اما در شش کشور باقی مانده، شبکه‌های عصبی MAE کمتری از خود نشان می‌دهند. با توجه به آنکه معیار RMSE دقیقتر از معیار MAE می‌باشد می‌توان به نتایج آن بیشتر تکیه کرد و بر پیش‌بینی دقیق‌تر شبکه‌ها صحه گذاشت. پس در کل شبکه‌های عصبی نتایج بهتری را برای پیش‌بینی تولید نفت خام از مدل‌های رگرسیون خطی نشان می‌دهند. همان‌طور که ملاحظه می‌شود در مورد کشورهای نیجریه و انگلستان، تفاوت معنی‌داری بین دو پیش‌بینی دیده نمی‌شود. اما در سایر موارد تفاوت معنی‌داری بین نتایج پیش‌بینی دیده می‌شود و از آنجا که در اغلب موارد

شبکه‌های عصبی پیش‌بینی بهتری نسبت به مدل‌های رگرسیون از خود نشان داده‌اند، نتیجه گرفته می‌شود که در کل، عملکرد شبکه‌های عصبی از مدل‌های رگرسیون خطی در پیش‌بینی تولید نفت خام در یازده کشور تولیدکننده بهتر است.

در خاتمه باید متذکر شد که هر چند در طی سال‌های اخیر روش‌های جدیدی نظیر روش‌های خودرگرسیون برداری و مدل‌های ARCH^۱ و GARCH^۲ نیز برای پیش‌بینی متغیرهای اقتصادی استفاده شده‌اند، اما همان‌طور که در بخش پیشینه تحقیق بیان شد، قدرت شبکه‌های عصبی در کارهای مشابه اقتصادی به اثبات رسیده است.

پیوست

مدل شبکه‌های عصبی مصنوعی


هوشمندی بالای سیستم عصبی انسان و قابلیت پردازش موازی و فوق‌العاده اطلاعات در مغز، همواره مورد تعجب و شگفتی بوده است. اما علیرغم این هوشمندی بالا، سرعت پردازش اطلاعات در مغز انسان بسیار پایین‌تر از ماشین‌های محاسبه‌گر می‌باشد. علت این است که اطلاعات در مغز انسان از طریق مواد شیمیایی جابجا می‌شوند. این پدیده انسان را به فکر طراحی سیستمی با قابلیت پردازش موازی همانند سیستم عصبی انسان، ولی سرعت محاسبه بالا انداخت.

اولین شبکه عصبی مصنوعی را روزنبلات^۳ در سال ۱۹۵۹ به نام پرسپترون^۴ طراحی کرد. این شبکه که یک شبکه طبقه‌بند^۵ بود صرفاً قابلیت یادگیری و حل مسائل خطی را داشت. بعد از آنکه پرسپترون نتوانست مسائل غیرخطی را مدل کند، برای مدتی بحث شبکه‌های عصبی کمتر مورد توجه دانشمندان قرار گرفت تا اینکه در سال ۱۹۸۲ آقای هاپفیلد^۶ با طراحی شبکه‌ای موسوم به هاپفیلد توانست یکی از پیچیده‌ترین مسائل بهینه‌سازی موسوم به TSP^۷ را حل کند. (در این

-
- 1- Autoregressive Conditional Heteroskedasticity
 - 2- Generalized Autoregressive Conditional Heteroskedasticity
 - 3- Rosenblatt
 - 4- Perceptron
 - 5- Classificated Network
 - 6- Hopfeild
 - 7- Traveling Salesman Problem

مسئله تاجری دوره گرد قصد سفر به n شهر را دارد و می‌خواهد بداند چگونه به این شهرها برود که از هر شهر یک بار بگذرد و با گذر از همه شهرها کمترین مسافت را طی کند (از اینجا بود که قدرت شبکه‌های عصبی روشن شد، بدین صورت که آنها قادرند برای تحولاتی چون سقوط بازار بورس و شوک‌های نفتی به عنوان انحرافات معنی‌دار از فرض خطی بودن، مدل‌های بهتری بسازند. بعد از آن، شبکه‌های عصبی بار دیگر مورد توجه دانشمندان قرار گرفت تا اینکه رم‌هالت^۱ و پارکر^۲ در ۱۹۸۶ با ارائه الگوریتم پس انتشار خطا^۳ (BP) شبکه پرسپترون را توسعه دادند و شبکه‌ای پیش‌خور^۴ چند لایه به نام پرسپترون چند لایه (MLP) ارائه کردند. در این مقاله نیز جهت پیش‌بینی تولید نفت خام هر کشور از این شبکه استفاده شده است. شبکه‌های عصبی چهار کار عمده انجام می‌دهند: ۱- تقریب^۵ (برازش) ۲- پیش‌بینی^۶ ۳- طبقه بندی^۷ ۴- خوشه بندی^۸. عمده‌ترین استفاده شبکه‌های عصبی در علم اقتصاد جهت پیش‌بینی می‌باشد.

در شکل (۲) شکل ساده یک نرون^۹ عصبی مصنوعی (اولین جزء اصلی یک شبکه عصبی) دیده می‌شود.



شکل ۲- مدل ساده یک نرون عصبی مصنوعی

$$\text{ورودی‌ها} = p_1, p_2, \dots, p_R$$

- 1- Rumel Hart
- 2- Parker
- 3- Back Propagation Algorithm
- 4- Feed Forward Neural Network
- 5- Approximation
- 6- Prediction
- 7- Pattern Classification
- 8- Clustering
- 9- Neuron

وزن‌های شبکه عصبی = $w_{1,1}, w_{1,2}, \dots, w_{1,R}$

$b =$ اریب (بایاس)

$$n = \sum b \cdot w_0 + p_1 \cdot w_{1,1} + p_2 \cdot w_{1,2} + \dots + p_R \cdot w_{1,R}$$

$$w_0 = 1$$

$f =$ تابع فعال سازی

$a = f(n)$ = خروجی نرون

حال به تعریف اجزایی یک نرون می پردازیم:

الف) ورودی‌ها: مجموعاً تشکیل لایه اول را می دهند در حقیقت ورودی‌ها نقش همان متغیرهای مستقل را در رگرسیون دارند.

ب) وزن‌ها: هر ورودی با یک بردار که درجه اهمیت آن ورودی را نشان می دهد داخل پردازشگر می شود.

ج) اریب: برای جابجایی، تابع فعال سازی مورد استفاده قرار می گیرد. در توابع فعال ساز خطی اریب می تواند همان نقش عرض از مبدأ را در رگرسیون دارا باشد.

د) تابع فعال سازی (تابع انگیزش)^۱: خروجی n را با استفاده از یک تبدیل مناسب پردازش می کند. این تابع که نقش مهمی در مدل سازی شبکه های عصبی بر عهده دارد، بسته به نوع شبکه عصبی متفاوت می باشد. اگر هدف ما پیش بینی باشد در لایه خروجی حتماً باید از تابع خطی استفاده کرد. اما اگر هدف طبقه بندی باشد باید از توابع محدود کننده مثل تابع تانژانت هیپربولیک^۲ استفاده کرد. اگر خروجی ما صرفاً محدود به اعداد مثبت باشد می توان از تابع فعال سازی لجستیک^۳ یا سیگموئید استفاده کرد.

$$f(x) = \frac{1}{1 + e^{(-ax)}}$$

تابع تجمعی لجستیک (سیگموئید): (۵)

-
- 1- Activation Function
 - 2- Hyperbolic Tangent
 - 3- Logistic Function

تابع تانژانت هیپربولیک^۱ (۶)

$$f(x) = \frac{1 - e^{-2ax}}{1 + e^{2ax}}$$

a در اینجا یک ضریب است.

از ترکیب چند نرون، یک شبکه عصبی به وجود می‌آید. ساده‌ترین شکل شبکه‌های عصبی، شبکه‌های عصبی تک لایه همانند آنچه ذکر شد، می‌باشند. زیرا که در شبکه‌های عصبی فرض بر این است که لایه اول صرفاً ورودی‌ها را از خود عبور می‌دهد و هیچ عمل پردازشی روی داده‌ها انجام نمی‌دهد. حال اگر بجای هر ورودی در شکل صفحه قبل از یک نرون استفاده شود مدل ساده شبکه تک لایه به دست می‌آید که در اینجا وزن‌ها نقش اهمیت اتصال هر نرون به نرون خروجی را ایفا می‌کنند. همان‌طور که بیان شد اگر هدف ما پیش‌بینی باشد در تابع فعال‌سازی، از توابع خطی که نوعی توابع غیرمحدودکننده هستند استفاده می‌شود. کاملاً روشن است که استفاده از یک شبکه تک لایه نمی‌تواند پیش‌بینی خوبی برای ما در حل مسائل پیچیده غیرخطی ارائه کند. در واقع تمام شبکه‌های عصبی با بیش از یک لایه در بخشی از کار خود از توابع غیرخطی فعال‌سازی استفاده می‌کنند. استفاده از توابع غیرخطی فعال‌سازی باعث می‌شود که توانایی‌های شبکه‌های عصبی در مدل کردن مسائل غیرخطی بروز نماید و جواب‌های مطلوبی در خروجی به ما بدهند. این ویژگی با یک تابع فعال‌سازی غیرخطی، مشتق‌پذیر و پیوسته اتفاق می‌افتد. بنابراین برای یک پیش‌بینی دقیق باید از شبکه‌های عصبی با بیش از یک لایه استفاده شود که در لایه‌های میانی آن توابع غیرخطی وجود داشته باشد.

طبقه‌بندی انواع آموزش

الف) یادگیری با نظارت^۲ ب) یادگیری بدون نظارت^۳

۴ - شکل مرسوم توابع تانژانت هیپربولیک در کتاب‌های ریاضی به صورت $\frac{e^n - e^{-n}}{e^n + e^{-n}}$ می‌باشد اما در ادبیات شبکه‌های عصبی

عموماً از شکل ذکر شده استفاده می‌شود. کاملاً مشخص است که با یک عملیات ساده ریاضی و فاکتورگیری از جمله e^{-n} در صورت و مخارج به رابطه فوق می‌رسیم. (برای توضیحات بیشتر در این زمینه به هیکین، ۱۹۹۹، رجوع شود).

2- Supervised Learning

3- Unsupervised Learning

در یادگیری با نظارت ابتدا زوج مرتب‌های (p, d) را به شبکه اعمال می‌کنیم. در این حالت شبکه هر دفعه خروجی خود را با خروجی مطلوب (d) مقایسه کرده و سعی در حداقل‌سازی خطای به دست آمده می‌کند. این کار چندین دفعه تکرار می‌شود تا بهترین مقادیر وزن‌ها با کمترین خطا به دست آیند. پس از آنکه شبکه به خوبی آموزش دید، حال می‌توان با استفاده از داده‌هایی که شبکه تا به حال آنها را مشاهده نکرده است به پیش‌بینی، طبقه‌بندی و ... پرداخت (Hakin, 1999).

یادگیری بدون نظارت مبتنی بر تجربه است و برحسب یک سری روابط تجربی کلی بین داده‌ها شبکه آموزش می‌بیند. این نوع یادگیری عموماً در خوشه‌بندی کاربرد دارد که در حوزه علم اقتصاد چندان استفاده نمی‌شود.

شبکه MLP

شبکه پرسپترون چند لایه، نوعی شبکه پیش‌خور چند لایه می‌باشد که حداقل یک لایه میانی یا پنهان^۱ دارد. شبکه‌های عصبی بسته به عملکردشان از الگوریتم‌های یادگیری متفاوتی استفاده می‌کنند. الگوریتم یادگیری در شبکه MLP، الگوریتم پس انتشار خطا می‌باشد. الگوریتم پس انتشار خطا را می‌توان تعمیم یافته قانون دلتا بنامیم.

تابع خطا در شبکه MLP:

$$\varepsilon_{(t)} = \frac{1}{2} e^2 \quad (7)$$

قانون دلتا^۲:

$$w_{(t+1)} = w_t + \Delta w_t \quad (8)$$

مقدار خطای تصحیح شده در زمان t :

$$\Delta w_t = \eta e_k p_{kj} \quad (9)$$

مقدار خطای مورد نظر:

1- Hidden Layer

2- Delta Rule

$$e_k = d_k - a_k \quad (10)$$

d_k : مقدار خروجی مطلوب

a_k : مقدار خروجی به دست آمده

η : نرخ یادگیری

e_k : خطای مشاهده شده:

W : وزن مربوطه:

p_{kj} : j : نرون k و خروجی از نرون

اثبات این قانون از روش تندترین شیب فرود^۱ بدست می‌آید که بیان می‌کند با حرکت‌های پی در پی خلاف جهت بردار گردایان خطا می‌توان به نقطه حداقل خطا رسید. این ادعا را نیز می‌توان با استفاده از بسط تیلور تایید کرد (Hakin, 1999).

گاهی برای افزایش سرعت یادگیری از الگوریتم‌های جانشین در شبکه عصبی MLP استفاده می‌شود. یکی از معروفترین این الگوریتم‌ها، الگوریتم (LM)^۲ است که در این تحقیق نیز برای یادگیری سریعتر شبکه از آن استفاده شده است. قاعده یادگیری در الگوریتم LM به صورت زیر می‌باشد:

$$w_{(k+1)} = w_k - [J'_k J_k + \mu I]^{-1} J'_k e_k \quad (11)$$

w = بردار وزن

J = ماتریس ژاکوبین^۳ که برابر مشتق‌های هر خطا نسبت به هر وزن می‌باشد.

μ = یک عدد ثابت است.

I = ماتریس واحد می‌باشد.

e = بردار خطا می‌باشد.

این الگوریتم، تقریبی از روش بهینه‌یابی گوس-نیوتن^۴ است. در روش گوس نیوتن داریم

-
- 1- Steepest Descent
 - 2- Levenberg – Marguardt
 - 3- Jacobian Matrix
 - 4- Gauss-Newton

$$w_{(k+1)} = w_k - (J'_k J_k)^{-1} J'_k e \quad (12)$$

حال روش LM علاوه بر روش گوس-نیوتن، روش تندترین شیب فرود را نیز دربردارد. بدین صورت که اگر μ عدد بزرگی شود، قانون فوق مشابه قانون تندترین شیب است اما اگر μ عدد کوچکی شود، قانون فوق معادل قانون گوس-نیوتن است. در قانون LM، μ متناسب با یادگیری مدل تغییر می‌کند. بنابراین هرچه به سمت کوچک‌تر شدن خطا پیش برویم سرعت محاسبات افزایش می‌یابد علت آن نیز در بالاتر بودن سرعت محاسبات از روش گوس-نیوتن است.

مسئله بعدی تعیین تعداد نرون‌های لایه‌های میانی و خروجی است. به جهت آنکه در تئوری یک خروجی داریم و هدف ما پیش‌بینی می‌باشد، نرون‌های لایه خروجی یک عدد است. در لایه میانی بهترین روش برای تعیین تعداد نرون‌ها روش آزمایش و خطا می‌باشد زیرا فرمول‌های ارایه شده برای این کار عموماً کلیت ندارند. در این تحقیق، مقدارهای مختلفی در آموزش شبکه برای نرون‌های لایه میانی انتخاب شده است و هر کدام که RMSE کمتری ارایه کرده است برای پیش‌بینی استفاده شده است.

References:

- 1- Ahmadi, Ahmad (2006). **Exchange Rate Forecasting With Neural Networks & Wavelet**. MS.c Thesis. Economic College of Tehran University.
- 2- Bosarge, W.E. (1993). **Adaptive Processes to Exploit the Nonlinear Structure of Financial Market**. In: R.R. Trippi and Turban (Eds.). *Neural Networks in Finance and Investing*. Probus Publishing. P.371-402.
- 3- Cremer, J & Isfahani, S. (1980). **A Competitive Theory of the Oil Market: What Does OPEC Really Do?** Working Paper, No.80-4. University of Pennsylvania.
- 4- Ezzati, A. (1976). **Future OPEC Price and Production Strategies as Affected by Its Capacity to Absorb Oil Revenues**. *Eur. Economics*, Vol 8, p. 107-138.
- 5- Falahi, Mohammad Ali. Khaloozade, Hamid & Hamidi, Saeed (2005). **Nonlinear Modeling and Forecasting The Jobs Taxes in Iran Economy** (The Application of Neural Networks and Compare it with Linear Regression and Time Series Models). *Economic Research Review*, Vol 76, P.143-167.
- 6- Griffin, James. M. (1985) **OPEC Behavior: A Test of Alternative Hypotheses** *American Economic Review*, Vol.75, No5, p.954-963.
- 7- Hakin Simon (1999). **Neural Network: A Comprehensive Foundation**, Prentice Hall.
- 8- IMF Annual Statistics (2007): The Central Bank of The Islamic Republic of

- Iran.
- 9- Ince, Huseyin & Trafalis, Theodore B. (2006). **A hybrid model for exchange rate prediction.** *Decision Support Systems*, Vol 42 ,P. 1054-1062.
 - 10- Kuan, Chang – Ming & White , Helbert (1994). **Artificial Neural Networks: An Econometric Perspective.** *Econometric Reviews*, Vol.13, P.1-91.
 - 11- Marzban H., Akbarian R., Javaheri B (2005). **A Comparison Between Among Econometric, Time Series and Neural Network Models for Exchange Rate Prediction.** *Economic Research Review*, Vol 69, p. 181-216.
 - 12- Maasoumi, E. Khotanzad, A and Abaye, A (1994). **Artificial Neural Networks for Some Macroeconomic Series: A First Report.** *Econometric Review*. Vol 13, p.105-122.
 - 13- Mac Avoy, P. (1982). **Crude Oil Prices as Determined by OPEC and Market Fundamentals.** Ballinger, Cambridge.
 - 14- Malik, Farooq & Nasereddin, Mahdi (2006). **Forecasting output using oil prices: A cascaded artificial neural network approach.** *Journal of Economics and Business*, Vol. 58, P. 168-180.
 - 15- Moshiri, Saeed (2001). **Inflation Forecasting in Iran With Use of Structural models, Time series and Neural Networks.** *Economic Research Review*, Vol 58, p. 140-184.
 - 16- Moshiri, Saeed & Brown, Laura (2003). **Unemployment Variability Over The Business Cycle: A Comparison of Forecasting Models.**
 - 17- Moshiri, Saeed & Cameron, Norman (2000). **Neural Network Versus Econometric Models in Forecasting Inflation.** *Journal of Forecasting*, Vol.19, P.201-217.
 - 18- Monthly Energy Review , October 2007. US Department of Energy.
 - 19- Nilsaz, Hamid (2006) **Neural Networks and Its Application in Ranking of Credit Applicants.** MS.C Thesis. Shahid Chamran University.
 - 20- Ramcharron, Harri (2001). **OPEC's Production under Fluctuating Oil Prices: Further Test of Target Revenue Theory.** *Energy Economics*, Vol.23, P. 667-681.
 - 21- Ramcharron, Harri (2002). **Oil Production Responses to Price Changes: An Empirical Application of Competitive Model to OPEC and non-OPEC Countries.** *Energy Economics* VOL.24, P.97-106.
 - 22- Refenes, A.P. (1995). **Neural Networks in the Capital Markets.** Wiley.
 - 23- Teece, D. (1982). **OPEC Behavior: an Alternative View**, In: Griffin ,J. M (ed), *OPEC Behavior and World Oil Prices*. Allen & Urwin, London.
 - 24- Wong, F.S (1990). **Time Series Forecasting Using Backpropagation Neural Networks,** *Neuro Computing* , Vol 2, P.147-159.

Received: 23.Dec.2007

Accepted: 10.Nov.2008