

## الگوسازی و پیش بینی آثار تغییرات قیمت نفت خام بر GDP کشورهای آمریکا و انگلستان

حمید ابریشمی، استاد دانشکده اقتصاد دانشگاه تهران\*

حجت الله غنیمی فرد، هیئت علمی دانشگاه صنعت نفت

مهدی احراری، کارشناس ارشد علوم اقتصادی

زهرا رحیمی، کارشناس ارشد علوم اقتصادی

### چکیده

در تحقیق حاضر، پیش بینی تغییرات قیمت نفت خام به عنوان منبع مهم انرژی بر تولید ناخالص داخلی کشورهای آمریکا (به عنوان بزرگترین مصرف کننده نفت) و انگلستان (به عنوان تولید کننده نفت) بررسی می شود. در این مطالعه با استفاده از شبکه عصبی GMDH و شبکه عصبی MLFF (به عنوان مدل های غیر خطی) به پیش بینی GDP آمریکا و انگلیس با ۲ الگو شامل: (۱) وقفه های قیمت نفت و GDP و (۲) فقط وقفه ای GDP، پرداخته می شود. نتایج حاصله با مدل ARIMA (به عنوان مدل خطی) مقایسه می شود. داده های مورد استفاده به صورت سالانه از سال ۱۹۵۲ تا سال ۲۰۱۰ می باشند. نتایج نشان می دهد که شبکه عصبی GMDH، با لحاظ وقفه های GDP و وقفه های نفت، بهترین عملکرد پیش بینی را در مورد هر دو کشور آمریکا و انگلستان به خود اختصاص داده است.

واژه های کلیدی: قیمت نفت خام، تولید ناخالص داخلی (GDP)، شبکه عصبی GMDH و MLFF، ARIMA

طبقه بندی JEL: C18، Q47

## ۱. مقدمه

در دنیای امروز پیش‌بینی به عنوان یک عنصر کلیدی در تصمیم‌گیری‌های مدیریتی و به منظور کنترل ریسک حائز اهمیت می‌باشد. توانایی پیش‌بینی با حداقل خطا باعث انتخاب بهتر می‌شود. یکی از مهم‌ترین کاربردهای مدل‌های مورد استفاده در اقتصاد، پیش‌بینی مقادیر آتی متغیرهای اقتصادی است. در حقیقت مدل‌ها را می‌توان با میزان صحت در پیش‌بینی‌شان مورد آزمون قرار داد. بدین ترتیب که اگر یک مدل اقتصادی در تبیین روابط موجود بین متغیرها موفق باشد، قادر به پیش‌بینی صحیح از آینده‌ی متغیرها نیز می‌باشد. بدیهی است که میزان صحت پیش‌بینی متغیرها جهت تصمیم‌گیری درست، عاملی مهم بشمار می‌آید. چنین اهمیتی سبب شده است تا تحقیقات در زمینه مدل‌ها و تکنیک‌های پیش‌بینی در چند دهه‌ی اخیر با شتاب بیشتری افزایش یابند. به طوری که امروزه در ادبیات اقتصاد سنجی کاربردی، شاهد مدل‌ها و روش‌های بسیاری در این زمینه می‌باشیم. برخی از این دستاوردها حاصل توسعه مدل‌ها و روش‌های موجود و برخی دیگر بر مبنای ارائه دیدگاه‌های جدید می‌باشند. از آنجا که دیدگاه سنتی و متداول در مدل‌سازی اقتصادی، مبتنی بر تبیین ارتباط بین متغیرهای اقتصادی است، اقتصاددانان با برآورد ارتباط بین متغیرهای مستقل و وابسته سعی در تبیین وضع موجود و پیش‌بینی مقادیر آتی متغیرهای وابسته دارند. این مدل‌ها به مدل‌های ساختاری شهرت دارند. البته، با توجه به وجود روابط غیرخطی پیچیده بین متغیرهای اقتصادی، مدل‌های ساختاری اگر چه قادر به تبیین نسبی وضع موجود بوده و از لحاظ تحلیلی به عنوان ابزاری مناسب

برای تصمیم‌گیری اقتصادی مورد استفاده قرار گرفته‌اند، اما در زمینه پیش‌بینی سابقه چندان موفقی از خود بر جای نگذاشته‌اند. بنابراین سایر روش‌های پیش‌بینی متغیرهای اقتصادی به عنوان رقیب مهم این مدل‌ها مطرح شده‌اند.<sup>۱</sup>

با توجه به اهمیت روز افزون پیش‌بینی برای تصمیم‌گیران به تدریج، شرایط و دیدگاه جدیدی برای مدل‌سازی مطرح شد. در این دیدگاه که به تحلیل سری‌های زمانی شهرت دارد، وظیفه‌ی پیش‌بینی متغیرهای اقتصادی بیش از هر چیز بر عهده خود این متغیرها می‌باشد. به عبارت دیگر از آنجا که یک متغیر اقتصادی حاوی کلیه اطلاعات مربوط به خود است و یا به عبارتی بیانگر کلیه کنش‌ها و ارتباط‌هایی است که منجر به شکل‌گیری آن می‌شود، لذا قوی‌ترین منبع برای توضیح تغییرات یک متغیر، خود آن متغیر می‌باشد.

در سال‌های اخیر دیدگاه دیگری به موازات مدل‌های سری زمانی در اقتصاد وارد شده است که بر طبق آن می‌توان با استفاده از هوش مصنوعی روابط بین متغیرها را، هر چند که پیچیده و غیرخطی باشند، توسط کامپیوتر فراگرفت و از آن برای پیش‌بینی مقادیر آتی استفاده نمود. گرچه هنوز زمان زیادی از ایجاد روش‌های محاسباتی مبتنی بر شبکه‌های عصبی نمی‌گذرد، لیکن این شبکه‌ها بدلیل دارا بودن ویژگی‌هایی چون پردازش موازی، هوشمندی و انعطاف‌پذیری، جایگاه چشم‌گیری در حل مسائل پیچیده از قبیل شناخت الگو، مدل‌سازی، تخمین و پیش‌بینی برای خود باز کرده است. مزیت مهم این مدل‌ها نسبت به

<sup>۱</sup> Marzban et al.

در دنیای امروز نفت به عنوان منبعی مهم و استراتژیک در سطح بین‌المللی مطرح است. این موضوع هم برای کشورهای صادرکننده نفت و هم برای واردکنندگان آن بسیار حائز اهمیت می‌باشد. هم اکنون با توجه به شرایط کلی اقتصادی سیاسی حاکم در سطح بین‌الملل، شاهد نوسان‌های روزانه قیمت نفت هستیم. با توجه به این که انرژی عامل مهمی در تولید ناخالص داخلی محسوب می‌شود، بنابراین تغییر قیمت انرژی تأثیر زیادی بر تولید ناخالص داخلی کشورها خواهد داشت.

در این مقاله، پیش‌بینی تغییرات قیمت نفت خام به عنوان منبع مهم انرژی بر تولید ناخالص داخلی کشورهای آمریکا و انگلستان بررسی می‌شود. از آنجا که آمریکا به عنوان بزرگترین مصرف‌کننده نفت در سطح بین‌المللی مطرح است و نوسان قیمت نفت در اقتصاد این کشور تأثیرگذاری بالایی دارد، در این مطالعه مورد بررسی قرار می‌گیرد. هم‌چنین انگلستان به عنوان تولیدکننده نفت خام در اروپا در این مطالعه بررسی می‌شود. تولید نفت انگلستان در سال ۲۰۱۰ میلادی، روزانه معادل ۱۴۵۲ هزار بشکه نفت بوده است که آن را در بین تولیدکنندگان عمده نفت در قاره اروپا قرار می‌دهد.<sup>۱</sup> بنابراین امکان بررسی متغیرها در کشوری که در مسند تولیدکننده و یا واردکننده نفت می‌باشد، وجود دارد. از آنجا که پیش‌بینی متغیرهای اقتصادی برای برنامه‌ریزی و سیاست‌گذاری از اهمیت بالایی برخوردار است، تغییرات GDP<sup>۲</sup> در آمریکا و انگلستان هر یک به گونه‌ای اقتصاد سایر کشورها از جمله ایران را متأثر می‌سازد. زیرا آن دو کشور در اقتصاد جهانی و در

سایر مدل‌ها عدم نیاز به اعمال فروض آماری خاص در مورد رفتار متغیرها مانند فروض مربوط به تابع توزیع احتمال و یا مانا بودن سریها می‌باشد. از آنجایی که اکثر سری‌های زمانی حقیقی غیرخطی هستند، بنابراین به کارگیری شبکه‌های عصبی توانائی در الگوسازی و پیش‌بینی سریهای زمانی را افزایش می‌دهد.

کاربرد موفق شبکه‌های عصبی در پیش‌بینی متغیرهای اقتصادی نشان می‌دهد که این شبکه‌ها می‌توانند به عنوان ابزاری مناسب در کنار سایر الگوها به منظور پیش‌بینی متغیرهای اقتصادی مورد استفاده قرار گیرند. الگوهای شبکه‌های عصبی را می‌توان در قالب الگوهای غیرتئوریک جای داد ولی می‌توان متغیرهای ورودی را بر اساس پایه‌های تئوریک تعیین کرد. لازم به ذکر می‌باشد که، شبکه‌های عصبی اگرچه در مقایسه با رگرسیون‌های معمولی، توانایی مدل‌سازی روابط غیرخطی را دارند ولی کاربرد این شبکه‌ها به منظور تفسیر و توضیح روابط بین متغیرها مناسب نمی‌باشد. اگر چه در شبکه‌های عصبی روابط بین متغیرهای خروجی و ورودی به وسیله‌ی معادلات نرون‌ها قابل بیان است ولی این روابط هیچ‌گونه تعبیر و تفسیر اقتصادی نخواهد داشت. شبکه‌های عصبی، روش‌های غیرخطی در برآورد روابط بین متغیرها هستند، لذا در صورتی که روابط بین متغیرها از یک فرآیند خطی تبعیت کند این شبکه‌ها ممکن است که نسبت به مدل‌های خطی نتایج بهتری ارائه نکنند. یکی از محدودیت‌های دیگر شبکه‌های عصبی این مسئله است که تعیین سهم مشخص هر یک از متغیرها در تغییرات متغیر وابسته به علت روابط پیچیده‌ی بین متغیرها چندان ساده نیست.

<sup>۱</sup> www.bp.com

<sup>۲</sup> Gross Domestic Product

مبادلات بین المللی سهم بسزائی دارند. بنابراین پیش بینی آثار تغییرات GDP این دو کشور به منظور سیاست گذاری های ارزی و تجاری در سایر کشورها از جمله در کشور ایران ضروری می باشد. بنابراین سوال اساسی این مطالعه بدین صورت مطرح می شود که آیا شبکه های عصبی در پیش بینی GDP با استفاده از قیمت نفت عملکرد قابل قبولی را ارائه می دهند؟

پس از بیان مقدمه، در بخش دوم خلاصه ای از مطالعات تجربی صورت گرفته ارائه می گردد. شبکه های عصبی در بخش سوم تشریح می شوند. در بخش چهارم نتایج تحقیق ارائه می شود. در نهایت نتیجه گیری و پیشنهادها پایان بخش مقاله خواهند بود.

## ۲. مطالعات تجربی

همیلتون<sup>۱</sup> (۱۹۸۳)، بیان می کند که از جنگ جهانی دوم تا اوایل دهه ۱۹۸۰ بین افزایش در قیمت نفت و رکود اقتصادی در آمریکا همبستگی مشاهده شده است. وی طی مطالعه ای که انجام می دهد این فرضیه را بررسی می کند که افزایش قیمت نفت علت اصلی رکود آمریکا است. همیلتون با استفاده از داده های فصلی به بررسی رابطه ی بین قیمت نفت و متغیرهای کلان اقتصادی، به ویژه تولید ناخالص داخلی پرداخت و با استفاده از آزمون علیت گرنجری به این نتیجه رسید که طی دوره ی مورد مطالعه، جهت علیت از سمت قیمت نفت به سمت تولید ناخالص داخلی است، یعنی تغییرات قیمت نفت علت گرنجری، تولید ناخالص داخلی است.

موری<sup>۲</sup> (۱۹۹۳)، در مقاله خود میزان تأثیر افزایش و کاهش قیمت نفت خام بر متغیرهای کلان اقتصادی آمریکا را بررسی کرد. وی این فرضیه را که افزایش قیمت نفت با متغیرهای کلان همبستگی بیشتری دارد ولی کاهش قیمت رابطه مشخصی با متغیرها نشان نمی دهد را ارزیابی نمود. در مورد عدم تقارن قیمت نفت او بیان کرد که، اثر افزایش قیمت بر اقتصاد معنی دار بوده است، در حالی که کاهش قیمت نفت اثر معنی داری بر اقتصاد ندارد و در کوتاه مدت به نفع اقتصاد نیست.

همیلتون (۱۹۹۶)، در مطالعه خود عنوان می کند که افزایش قیمت نفت به صورت فصلی از سال ۱۹۸۵، نسبت به قبل متفاوت شده است. وی به اثر غیرمقارن قیمت نفت اشاره می کند. به این شکل که افزایش قیمت نفت بر متغیرها اثر بزرگی دارد در صورتی که در مورد کاهش قیمت نفت این اثر صفر می باشد.

همیلتون (۲۰۰۳)، اثرات غیرخطی قیمت نفت بر رشد GDP را بررسی کرد. وی در مقاله خود شواهدی از غیر خطی بودن این رابطه بیان می کند و عنوان می کند که به علت این که مشاهدات نشان دهنده ی رابطه ی غیرخطی بین قیمت نفت و فعالیت های اقتصادی است، استفاده از مدل خطی به جای مدل غیرخطی ما را دچار خطای تصریح<sup>۳</sup> خواهد ساخت. البته در روش غیرخطی نیز تصریح های مختلف متصور است. همیلتون برای پیدا کردن بهترین مدل، در معادله ای غیرخطی فضای احتمال را وارد کرده و حالت های ممکن را با یکدیگر مقایسه می کند. در واقع همیلتون بیان کرد که ارتباط بین

<sup>2</sup> Mory

<sup>3</sup> Misspecification

<sup>1</sup> Hamilton

آن را با مدل گام تصادفی، مدل اتورگرسیو و مدل خطی مقایسه می کنند.

با توجه به این که شبکه های عصبی بسیار گسترده هستند و انواع مختلفی دارند در مطالعه حاضر از شبکه عصبی<sup>۳</sup> GMDH و شبکه عصبی<sup>۴</sup> MLFF استفاده می شود و نتایج حاصل از پیش بینی های آن با روش خطی<sup>۵</sup> ARIMA مقایسه می شود.

### ۳. شبکه های عصبی مصنوعی

یک شبکه ی عصبی مصنوعی (ANN)<sup>۶</sup> یک الگوی ریاضیاتی یا محاسباتی است که بر اساس شبکه های عصبی طبیعی<sup>۷</sup> پایه ریزی شده و از یک گروه از نرون های مصنوعی مرتبط با هم تشکیل شده است. هم چنین این شبکه ها ابزارهای مدل سازی داده های آماری به صورت غیرخطی هستند که با استفاده از سرعت محاسباتی کامپیوتر روابط بین داده ها را هر چند هم که پیچیده باشد فراگرفته و از آن به منظور پیش بینی مقادیر آتی متغیرها استفاده می کنند.

هر نوع از شبکه های عصبی منطبق بر دسته ای از توابع ریاضیاتی است به صورت  $f: X \rightarrow Y$  است. لغت شبکه در عبارت شبکه ی عصبی مصنوعی به این دلیل مطرح می شود که تابع  $f(x)$  ترکیبی از توابع دیگری مانند  $g(x)$  است که خود می تواند به صورت ترکیبی از سایر توابع باشد.

GDP و قیمت نفت به صورت غیرخطی و پیچیده می باشد که در مطالعه حاضر با استناد به مطالعه همیلتون، از شبکه عصبی به عنوان روشی غیرخطی جهت پیش بینی GDP با لحاظ قیمت های نفت استفاده می شود.

رودریگوئز و سانچز<sup>۱</sup> (۲۰۰۴)، از مدل VAR خطی و غیرخطی برای بررسی اثر نوسانات قیمت نفت بر روی فعالیت های واقعی در کشورهای صنعتی استفاده می کنند و سه روش تصریح نامتقارن، تصریح مقیاس و تصریح خالص را برای تجزیه قیمت به کار می برند. ایشان به شواهدی از تاثیر غیرخطی قیمت های نفت بر GDP اشاره می کنند، به ویژه این که افزایش قیمت نفت بر روی رشد GDP اثری بیشتر از کاهش قیمت دارد. رودریگوئز و سانچز در مطالعه خود با استفاده از مدل VAR خطی و غیرخطی به بررسی تأثیر نوسان های قیمت نفت بر روی فعالیت های واقعی اقتصاد پرداختند. در مطالعه حاضر نیز با استفاده از تصریح غیرخطی شبکه عصبی، پیش بینی GDP با استفاده از قیمت نفت انجام می شود.

مالیک و نصرالدین<sup>۲</sup> (۲۰۰۵)، در مطالعه خود به پیش بینی GDP آمریکا با استفاده از قیمت های نفت می پردازند. ایشان در مطالعه خود GDP را با استفاده از ۳ مدل خطی و ۲ مدل شبکه عصبی آبخاری و شبکه عصبی مرسوم پیش بینی کرده و نتایج آن ها را با هم مقایسه می کنند. مالیک و نصرالدین در مطالعه خود در واقع شبکه عصبی آبخاری را معرفی کرده و از این روش جهت پیش بینی GDP استفاده می کنند و نتایج حاصل از

<sup>3</sup> Group Method of Data Handling

<sup>4</sup> Multi Layer Feed Forward

<sup>5</sup> Autoregressive Integrated Moving Average

<sup>6</sup> Artificial Neural Networks

<sup>7</sup> Biological Neural Networks

<sup>1</sup> Rodriligues and Sanchez

<sup>2</sup> Malik and Nasereddin

### ۱.۳. شبکه عصبی GMDH

الگوریتم GMDH توسط ایواخنکو و همکاران (۱۹۸۳)<sup>۱</sup> به عنوان یک روش یادگیری برای مدل سازی سیستم های پیچیده و غیرخطی معرفی شده است. این الگوریتم تکنیکی سلسله مراتبی برای ساخت و آموزش شبکه های چند جمله ای ارائه می دهد. بدین ترتیب که تعداد زیادی مدل ساده را در نظر گرفته، بهترین ها را دوباره آموزش داده و مدل های جدید را بر مبنای آن ها می سازد. در نهایت ترکیبی از این مدل ها به عنوان مدل نهایی و در قالب یک شبکه جلورو بدست می آید. در این شبکه هر یک از واحدهای پردازشگر شبکه دارای دو ورودی و یک خروجی هستند. بلوک های سازنده مدل و یا همان واحدهای چند جمله ای معمولاً به فرم چند جمله ای درجه ۲ به صورت رابطه ۱ هستند:

$$Z = f(x_1, x_2) = a_0 + a_1x_1 + a_2x_1 + a_3x_1^2 + a_4x_1^3 + a_5x_1x_2 \quad (1)$$

در رابطه فوق،  $x_1$  و  $x_2$  ورودی های واحد،  $a_i$  ها ضرایب (وزنها) و  $Z$  خروجی مدل هستند. الگوریتم یادگیری شبکه GMDH شامل مراحل زیر است:

(۱) داده های ورودی که شامل متغیر وابسته خروجی  $y$  و مستقل  $x_1, x_2, \dots, x_n$  هستند، به دو مجموعه آموزش<sup>۲</sup> و تست<sup>۳</sup> تقسیم می شوند.

(۲) داده های ورودی که شامل  $n$  متغیر ورودی هستند، در لایه ورودی قرار می گیرند و  $\binom{n}{2}$  واحد در لایه اول

قرار می گیرند (یعنی به ازای تمام ترکیب های دوتایی ممکن متغیرهای ورودی).

(۳) برای هر یک از واحدهای چند جمله ای، ضرایب مربوطه با استفاده از داده های آموزش برآورد می شوند.

(۴) با استفاده از داده های تست، به هر یک از واحدها یک مقدار خطا نسبت داده می شود.

(۵) خطای هر یک از واحدها با یک حد آستانه مقایسه می شود. اگر این مقدار از حد آستانه بزرگ تر بود، آن واحد حذف می گردد و گرنه باقی مانده و به عنوان ورودی لایه بعد در نظر گرفته می شود.

(۶) اگر خطای بهترین واحد لایه جاری از خطای بهترین واحد لایه قبل بزرگتر باشد، می توان نتیجه گرفت که در اثر اضافه کردن این لایه بهبودی در مدل حاصل نشده است. بنابراین تعداد لایه ها جهت مدل سازی به حد مطلوب رسیده است. در این حالت آخرین لایه اضافه

شده حذف می گردد و مرحله ۸ شروع می شود.

(۷) خروجی واحدهای لایه جاری به عنوان ورودی لایه بعد قرار می گیرد. اگر تعداد این واحدها  $m$  باشد، به ازای ترکیب های دوتایی آنها  $\binom{m}{2}$  واحد در لایه بعد قرار می گیرد. پس از ساخت واحدهای لایه جدید به مرحله ۳ برمی گردد.

(۸) در این مرحله خروجی واحد دارای کمترین خطا به عنوان خروجی نهایی مدل معرفی می گردد. شبکه نهایی به صورت بازگشتی و از روی مسیر منتهی به خروجی بدست می آید که در نتیجه، واحدهایی از لایه های قبل که اتصالی با واحد خروجی ندارند حذف می گردند (فوجی موتو و ناکابایاشی، ۲۰۰۳)<sup>۴</sup>.

<sup>1</sup> Ivakhnenko et al.

<sup>2</sup> Training Set

<sup>3</sup> Checking Set

<sup>4</sup> Fujimoto and Nakabayashi

الگوریتم پس انتشار خطا<sup>۳</sup> یکی از معمول ترین الگوریتم های یادگیری نظارت شده در شبکه های عصبی چند لایه پیشرو<sup>۴</sup> محسوب می شود. اساس این الگوریتم بر تصحیح پارامترهای آزاد شبکه با توجه به خطای شبکه و یا تفاوت پاسخ واقعی شبکه و پاسخ مطلوب است. در این روش سعی می شود تا مربع خطای بین خروجی های شبکه و تابع هدف حداقل شود، اما تضمینی برای این که این الگوریتم به حداقل مطلق برسد وجود ندارد.

پایه سازی الگوریتم فوق در شبکه ای با  $n_{in}$  گره ورودی،  $n_{hidden}$  گره مخفی و  $n_{out}$  گره خروجی طی مراحل زیر انجام می گیرد (بیات ۱۹۹۷)<sup>۵</sup>.

- (۱) همه وزن ها با یک مقدار تصادفی کوچک عدددهی می شوند.
- (۲) تا رسیدن به شرط پایانی مراحل ۳ تا ۸ اجرا می شوند.
- (۳) هر مقدار از بردار ورودی که متعلق به مجموعه آموزش است، به سمت جلو در شبکه انتشار می یابد.<sup>۶</sup>
- (۴) خطای E به سمت عقب در شبکه انتشار می یابد.
- (۵) برای هر مقدار X مقدار خروجی هر واحد محاسبه می شود تا به گره های خروجی برسد.
- (۶) برای هر واحد خروجی، جمله ی خطا محاسبه می شود.
- (۷) برای هر واحد مخفی جمله خطا محاسبه می شود.

شبکه GMDH، شبکه ای خودسامانده<sup>۱</sup> است و نیازی به تعیین ساختار آن از قبل نیست. تنها پارامتری که نیاز به تنظیم دارد، حد آستانه حذف واحدهای شبکه در مرحله ۵ الگوریتم است. یکی از مزیت های شبکه GMDH آن است که از بین متغیرهای ورودی، متغیرهایی که نسبت به سایر متغیرها اثرگذاری کمتری بر متغیر خروجی دارند را شناسایی می کند و در مدل سازی دخالت نمی دهد. هدف از طراحی این نوع شبکه، جلوگیری از رشد واگرایی شبکه و نیز مرتبط کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی است، به گونه ای که با تغییر این پارامترها، ساختار شبکه ها نیز تغییر کند. بنابراین خروجی های مدل با دقت بالا و حداقل خطا به دست می آیند و جهت پیش بینی های اقتصادی بسیار مناسب می باشند.

### ۲.۳. شبکه عصبی MLFF

از نظر برگشت پذیری دو نوع شبکه پیش خور و شبکه برگشتی<sup>۲</sup> وجود دارد. در شبکه پیش خور مسیر پاسخ همواره رو به جلو پردازش می شود و به نورون های لایه های قبلی باز نمی گردد. اگر ایده شبکه های پیش خور به چند لایه تعمیم داده شود، هر لایه ماتریس وزن w و بردار ورودی X و بردار خروجی Z مختص خود را دارد. در شبکه های برگشتی حداقل یک سیگنال برگشتی از یک نورون به همان نورون یا نرون های همان لایه یا لایه های قبل وجود دارد.

<sup>3</sup> Back Propagation

<sup>4</sup> Multi Layer Feed Forward (MLFF)

<sup>5</sup> Bayat

<sup>6</sup> شبکه به صورت پیشرو تعریف شده است.

<sup>1</sup> Self-Organizing

<sup>2</sup> Recurrent

۸) مقدار هر وزن با توجه به جمله خطا تغییر می‌یابد. معمولاً الگوریتم پس انتشار خطا پیش از خاتمه، هزاران بار با استفاده از همان داده‌های آموزشی تکرار می‌گردد و شروط مختلفی را می‌توان برای خاتمه الگوریتم به کار برد.

#### ۴. نتایج تحقیق

در این قسمت الگوسازی و پیش‌بینی اثر تغییر قیمت نفت خام بر GDP کشورهای آمریکا و انگلستان صورت پذیرفته است. بروز شوک‌های نفتی در دهه‌های گذشته لزوم بررسی و پیش‌بینی تغییرات قیمت نفت بر GDP را آشکار می‌کند. مطالعات همیلتون در سال ۲۰۰۳ نشان می‌دهد که قیمت نفت در یک سیستم غیرخطی بر تولید اثر می‌گذارد، اما هیچ‌گونه توافق آشکاری در مورد شکل تابع این سیستم غیرخطی وجود ندارد. با توجه به ارتباط غیرخطی نفت و تولید، در این مطالعه از شبکه‌ی عصبی به عنوان یک سیستم غیرخطی که ابزاری قدرتمند جهت پیش‌بینی است، استفاده شده است. اطلاعات مربوط به GDP آمریکا از سایت <http://www.bea.gov><sup>۱</sup> و اطلاعات مربوط به GDP انگلستان از <http://www.statistics.gov.uk><sup>۲</sup> به دست آمده است. هم‌چنین آمار مربوط به قیمت نفت خام از سایت <http://www.bp.com> استفاده شده است.

#### ۱.۴. پیش‌بینی با استفاده از شبکه عصبی GMDH

مدل‌سازی و پیش‌بینی شبکه عصبی GMDH در برنامه MATLAB انجام شده است. متغیرهای ورودی برای مدل‌سازی و پیش‌بینی شامل رشد GDP واقعی و رشد قیمت جهانی نفت خام هستند. خروجی سیستم، پیش‌بینی GDP می‌باشد که نوسان‌های قیمت نفت خام در آن منعکس شده است. در واقع سیستم از وقفه‌های GDP و وقفه‌های قیمت نفت خام برای پیش‌بینی GDP استفاده کرده است.

در این مطالعه از دو لایه پنهان جهت الگوسازی و پیش‌بینی متغیر هدف استفاده شده است. لازم به ذکر است که تعداد لایه‌های پنهان می‌تواند بیشتر شود. افزایش تعداد لایه‌های پنهان سبب کاهش خطای مدل‌سازی می‌شود ولی این امر سبب پیچیده‌تر شدن محاسبات نیز خواهد شد. استفاده از لایه‌های بیشتر با مشکلاتی هم‌چون افزایش حجم و زمان انجام محاسبات، افزایش احتمال بیش‌برازش، افزایش تعداد معادلات نهایی و پیچیدگی فرآیند پیش‌بینی همراه است. لذا محقق باید یا تعداد لایه‌ها را به منظور کاهش خطا، افزایش دهد و یا با ساده‌سازی و استفاده از متغیرهایی که بیشترین تأثیر را بر متغیر هدف دارند، حجم معادلات و زمان تخمین را کاهش دهد.

لازم به ذکر می‌باشد که، کلیه متغیرها به صورت تفاضل در لگاریتم هستند و مدل‌سازی و پیش‌بینی بر اساس رشد متغیرها است. برای مدل‌سازی در الگوریتم شبکه عصبی GMDH از وقفه‌های متغیرهای رشد قیمت نفت و رشد GDP استفاده می‌شود. از آنجایی که پیش‌بینی به صورت یک گام به جلو انجام می‌شود، از وقفه‌های متغیرها به عنوان متغیرهای ورودی استفاده

<sup>۱</sup> Bureau Of Economics Analysis

<sup>۲</sup> UK Statistics Authority



میانگین مربعات خطا (RMSE)، میانگین قدرمطلق خطا (MAE<sup>۲</sup>) و میانگین قدرمطلق درصد خطا (MAPE<sup>۳</sup>) استفاده شده که نتایج آنها در جدول (۳) گزارش شده است.

#### ۴.۲. پیش‌بینی با استفاده از شبکه عصبی (MLFF)

در این قسمت به الگوسازی و پیش‌بینی اثر تغییر قیمت نفت خام بر GDP آمریکا و انگلستان، با استفاده از شبکه عصبی MLFF پرداخته می‌شود. این برنامه تحت نرم‌افزار<sup>۴</sup> SPSS Clementine اجرا می‌شود. مدل نیز به صورت دو لایه برآورد می‌شود. در این بخش نیز پس از به‌دست آوردن وقفه‌های بهینه متغیرهای ورودی، مدل برآورد می‌شود. متغیرهای ورودی در مورد آمریکا، عبارت از وقفه اول تولید ناخالص داخلی و وقفه اول قیمت جهانی نفت خام می‌باشند.

در مورد کشور انگلستان نیز متغیرهای ورودی عبارت از وقفه‌های اول و دوم تولید ناخالص داخلی و وقفه‌های اول و دوم قیمت جهانی نفت خام می‌باشند. با توجه به متغیرهای ورودی پیش‌بینی صورت می‌گیرد. میزان خطای پیش‌بینی با استفاده از روش MLFF با توجه به معیارهای مختلف محاسبه شده است که در جدول (۴) ارائه شده است.

می‌شود. هم‌چنین برای تعیین تعداد بهینه وقفه‌های متغیرهای ورودی، با توجه به سالانه بودن داده‌ها ۱ و ۲ وقفه استفاده می‌شود. در ادامه مدل‌های زیر برآورد شده‌است. مدلی که پیش‌بینی آن کمترین مقدار ریشه‌ی میانگین مربعات خطا (RMSE<sup>۱</sup>) را داشته باشد، به عنوان مدل نهایی برای انجام الگوسازی و پیش‌بینی انتخاب شده است. نتایج مربوط به آمریکا در جدول (۱) و نتایج مربوط به انگلستان در جدول (۲) گزارش شده است.

با توجه به نتایج جدول (۱)، برای انجام دادن پیش‌بینی، از GDP آمریکا با یک وقفه و از قیمت نفت نیز با یک وقفه استفاده می‌شود. بنابراین متغیرهای ورودی عبارت از وقفه اول تولید ناخالص داخلی و وقفه اول قیمت جهانی نفت خام هستند. با توجه به متغیرهای ورودی پیش‌بینی صورت می‌گیرد. هر دو متغیرهای  $OIL_{t-1}$  و  $GDP_{t-1}$  به عنوان متغیرهای مهم و تأثیرگذار انتخاب شده‌اند و بر مبنای این متغیرها، الگوسازی و پیش‌بینی صورت گرفته‌است.

با توجه به نتایج جدول (۲)، برای انجام پیش‌بینی، از GDP انگلستان با دو وقفه و از قیمت نفت نیز با دو وقفه استفاده می‌شود. بنابراین متغیرهای ورودی عبارت از وقفه‌های اول و دوم تولید ناخالص داخلی و وقفه‌های اول و دوم قیمت جهانی نفت خام می‌باشند. در این حالت سیستم متغیرهای  $OIL_{t-1}$ ،  $GDP_{t-2}$ ،  $GDP_{t-1}$  و  $OIL_{t-2}$  را مهم تشخیص داده‌است و بر اساس این متغیرها، الگوسازی و پیش‌بینی صورت گرفته‌است.

برای محاسبه میزان خطای پیش‌بینی معیارهای مختلفی وجود دارد. در این مطالعه از معیارهای ریشه‌ی

<sup>۲</sup> Mean Absolute Error

<sup>۳</sup> Mean Absolute Percentage Error

<sup>۴</sup> این نرم‌افزار برای آنالیزهای آماری به صورت سرور و کلاینت استفاده می‌شود و در واقع محاسبات بسیار پیچیده را به صورت متمرکز می‌توان به وسیله آن انجام داد. این نرم‌افزار ابتدا تحت سیستم عامل‌های یونیکس و لینوکس اجرا می‌شد ولی نسخه‌های جدید آن در محیط ویندوز نیز قابل نصب است و قابلیت استفاده از پایگاه داده‌هایی مانند SQL را نیز دارد.

<sup>۱</sup> Root Mean Square Error

**جدول (۱): محاسبه‌ی میزان RMSE به ازای وقفه‌های مختلف GDP و نفت در آمریکا**

متغیرها	GDP <sub>t-1</sub>	GDP <sub>t-1</sub> و GDP <sub>t-2</sub>
OIL <sub>t-1</sub>	۰/۰۰۳۵۲	۰/۰۰۵۵۷
OIL <sub>t-2</sub> و OIL <sub>t-1</sub>	۰/۰۰۳۸۶	۰/۰۰۳۷۲

منبع: یافته‌های تحقیق

**جدول (۲): محاسبه‌ی میزان RMSE به ازای وقفه‌های مختلف GDP و نفت انگلستان**

متغیرها	GDP <sub>t-1</sub>	GDP <sub>t-1</sub> و GDP <sub>t-2</sub>
OIL <sub>t-1</sub>	۰/۰۰۴۱۶	۰/۰۰۳۳۷
OIL <sub>t-2</sub> و OIL <sub>t-1</sub>	۰/۰۰۳۳۶	۰/۰۰۳۱۹

منبع: یافته‌های تحقیق

**جدول (۳): میزان خطای پیش‌بینی با استفاده از معیارهای مختلف در روش GMDH (بر اساس وقفه‌های نفت و GDP)**

RMSE	MAE	MAPE	معیار خطا / کشور
۰/۰۰۳۵۲	۰/۰۰۳۱	۰/۲۸۵	آمریکا
۰/۰۰۳۱۹	۰/۰۰۲۷	۰/۱۹۶	انگلستان

منبع: یافته‌های تحقیق

**جدول (۴): میزان خطای پیش‌بینی با استفاده از معیارهای مختلف در روش MLFF (بر اساس وقفه‌های نفت و GDP)**

RMSE	MAE	MAPE	معیار خطا / کشور
۰/۰۰۴۵۸	۰/۰۰۴۰۰	۰/۴۸۲	آمریکا
۰/۰۰۳۵۴	۰/۰۰۳۳۰	۰/۲۲۳	انگلستان

منبع: یافته‌های تحقیق

تولید ناخالص داخلی و وقفه دوم تولید ناخالص داخلی هستند.

سیستم، هر دو متغیر را مؤثر تشخیص داده و با استفاده از  $GDP_{t-1}$  و  $GDP_{t-2}$  به پیش بینی و مدل سازی پرداخته است. میزان خطای پیش بینی با توجه به معیارهای مختلف به شرح جدول (۵) است.

با مقایسه ی خطای پیش بینی روش GMDH و MLFF روشن می شود که الگوریتم GMDH با توجه به متغیرهای ورودی، بهتر توانسته به الگوسازی و پیش بینی پردازد و میزان خطای پیش بینی در روش GMDH نسبت به روش MLFF کاهش یافته است.

با توجه به مطالعات صورت گرفته توسط مالیک و نصرالدین (۲۰۰۵)<sup>۱</sup>، قیمت های نفت را می توان به عنوان ابزار قدرتمندی برای پیش بینی GDP به کار برد. در قسمت های قبلی این مطالعه با استفاده از وقفه های GDP و وقفه های قیمت نفت پیش بینی GDP انجام شد. به دنبال پیش بینی های صورت گرفته در قسمت قبلی در این قسمت به پیش بینی GDP با استفاده از روش شبکه عصبی GMDH (صرفاً بر اساس وقفه های GDP) و شبکه عصبی MLFF (صرفاً بر اساس وقفه های GDP) و روش ARIMA پرداخته می شود. در انتها می توان نتایج به دست آمده را با یکدیگر مقایسه کرد.

### ۴.۳. پیش بینی با استفاده از روش شبکه ی عصبی GMDH صرفاً بر اساس وقفه های GDP

در این قسمت الگوسازی و پیش بینی مدل با استفاده از برنامه ی شبکه ی عصبی GMDH، صرفاً بر اساس وقفه های GDP انجام می شود. برای الگوسازی و پیش بینی از مدل دولایه استفاده می شود.

با توجه به سالانه بودن داده ها در این مطالعه، از ۲ وقفه جهت ادامه بررسی استفاده می شود. متغیرهای ورودی در مورد آمریکا و انگلستان عبارت از وقفه اول

<sup>1</sup> Malik and Nasereddin

**جدول (۵): میزان خطای پیش‌بینی با استفاده از معیارهای مختلف در روش GMDH (بر اساس وقفه‌های GDP)**

معیار خطا کشور	MAPE	MAE	RMSE
آمریکا	۰/۲۷۱	۰/۰۰۳۳۸	۰/۰۰۳۶۸
انگلستان	۰/۲۰۷	۰/۰۰۲۷۵	۰/۰۰۳۳۹

منبع: یافته‌های تحقیق

انگلستان عبارت از وقفه اول تولید ناخالص داخلی و وقفه دوم تولید ناخالص هستند. با توجه به متغیرهای ورودی پیش‌بینی صورت می‌گیرد. میزان خطای پیش‌بینی با توجه به معیارهای مختلف به شرح جدول (۶) است.

**۴.۴. پیش‌بینی با استفاده از روش شبکه عصبی**

**MLFF صرفاً بر اساس وقفه‌های GDP**

در این بخش الگوسازی و پیش‌بینی مدل با استفاده از شبکه عصبی MLFF صرفاً بر اساس وقفه‌های GDP صورت می‌گیرد. جهت انجام پیش‌بینی از مدل دولایه استفاده می‌شود. متغیرهای ورودی در مورد آمریکا و

**جدول (۶): میزان خطای پیش‌بینی با استفاده از معیارهای مختلف در روش MLFF (بر اساس وقفه‌های GDP)**

معیار خطا کشور	MAPE	MAE	RMSE
آمریکا	۰/۵۱۱	۰/۰۰۴۰۱	۰/۰۰۴۷۱
انگلستان	۰/۲۳۰	۰/۰۰۳۳۵	۰/۰۰۳۸

منبع: یافته‌های تحقیق

برای مانا کردن سری‌های زمانی در واریانس از لگاریتم‌گیری و برای مانا کردن سری‌های زمانی در میانگین از تفاضل‌گیری استفاده می‌شود (ابریشمی و مهر آرا، ۲۰۰۲). لذا ابتدا از سری زمانی مربوط به GDP، لگاریتم گرفته و الگو را بر اساس لگاریتم آن برآورد و انتخاب می‌کنیم. در مورد کشور آمریکا و انگلستان سری لگاریتم GDP آن بررسی می‌شود. نمودار لگاریتم GDP نشان‌دهنده وجود نامانایی در این سری است. سپس آزمون ADF<sup>۲</sup> در سری‌های مورد نظر انجام شده که نتایج آن در جدول (۷) گزارش شده است.

**۴.۵. پیش‌بینی با استفاده از روش ARIMA**

مدل‌سازی سری‌های زمانی به روش باکس - جنکینز (ARIMA) شامل مراحل شناسایی، تشخیص، تخمین و بازبینی تشخیصی است. به طور خلاصه مراحل کار را می‌توان به صورت زیر تقسیم‌بندی کرد:

(۱) مانا کردن سری زمانی با تفاضل‌گیری (تعیین d)

(۲) یافتن (p,q) برای تخمین پارامترها

(۳) تخمین الگو

(۴) کنترل

(۵) آزمون خوب بودن برازش الگو

(۶) پیش‌بینی بر اساس الگوی انتخاب شده

<sup>1</sup> Abrishami and Mehrara

<sup>2</sup> Augmented Dickey-Fuller

جدول (۷): آزمون ADF برای سری های GDP آمریکا و انگلستان

متغیر	مدل	Augmented Dickey-Fuller test statistic	مقدار بحرانی در سطح ۰.۵٪
LGDP آمریکا	شامل عرض از مبدأ و روند	-۲/۳۲	-۳/۴۹
LGDP انگلستان	شامل عرض از مبدأ و روند	-۳/۰۹	-۳/۴۹

منبع: یافته های تحقیق

از آنجایی که قدرمطلق آماره‌ی آزمون مربوطه کمتر از مقدار بحرانی است، در نتیجه فرضیه‌ی وجود ریشه‌ی واحد را نمی‌توان رد کرد. بنابراین برای مانا کردن سری لگاریتم GDP، از سری تفاضل گرفته و مجدداً آزمون ریشه‌ی واحد انجام می‌شود، که نتایج آن در جدول (۸) آمده است.

جدول (۸): آزمون ADF برای سری های D(LGDP) آمریکا و انگلستان

متغیر	مدل	Augmented Dickey-Fuller test statistic	مقدار بحرانی در سطح ۰.۵٪
DLGDP آمریکا	شامل عرض از مبدأ	-۶/۹۸	-۲/۹۱
DLGDP انگلستان	شامل عرض از مبدأ	-۶/۱۸	-۲/۹۱

منبع: یافته های تحقیق

الگوی نهایی انتخاب می‌شود (جدول ۹). بنابراین، با توجه به معیارهای AIC و SBC، در مورد آمریکا مدل ARIMA (1,1,1) جهت تخمین و پیش‌بینی انتخاب می‌شود، که نتایج مربوط در جدول (۹) گزارش شده است. جدول (۱۰) نیز معیارهای محاسبه شده AIC و SBC را برای انگلستان گزارش می‌کند، که در آن مجدداً مدل ARIMA (1,1,1) جهت تخمین و پیش‌بینی انتخاب می‌شود.

از آنجایی که قدرمطلق آماره‌ی آزمون ADF بزرگ‌تر از مقدار بحرانی است، در نتیجه فرضیه‌ی صفر مبنی بر غیر ساکن بودن سری D(LGDP) رد می‌شود. بنابراین الگوسازی توسط سری D(LGDP) صورت می‌گیرد. با بررسی نمودار توابع خود همبستگی D(LGDP) و خود همبستگی جزئی نمونه، مشخص می‌شود که رفتار این توابع همانند رفتار توابع الگوهای مرسوم و از قبل مشخص شده نمی‌باشند، لذا چندین الگو را با توجه به سالانه بودن داده‌ها در نظر گرفته و پس از برآورد آنها بر اساس معیارهای AIC<sup>۱</sup> و SBC<sup>۲</sup>،

<sup>۱</sup> Akaike Information Criterion<sup>۲</sup> Schwartz Bayesian Criterion

جدول (۹): برآورد الگوهای مختلف براساس معیارهای AIC و SBC در آمریکا

			Q
۲	۱	۰	P
-۶/۲۳	-۲۰/۳	-۶/۲۵	۰
(-۱۲/۱۶)	(-۶/۱۹)	(-۶/۲۰)	۰
-۶/۲۲	-۶/۹۳	-۶/۲۴	۱
(-۶/۱۱)	* (-۶/۸۷)	(-۶/۱۵)	۱
-۶/۴۸	-۶/۲۶	-۶/۳۷	۲
(-۶/۳۲)	(-۶/۱۴)	(-۶/۱۹)	۲

منبع: یافته‌های تحقیق (اعداد داخل پرانتز مربوط به آماره SBC است)

جدول (۱۰): برآورد الگوهای مختلف براساس معیارهای AIC و SBC در انگلستان

			Q
۲	۱	۰	P
-۶/۵۹	-۶/۶۵	-۶/۶۲	۰
(-۶/۵۲)	(-۶/۵۵)	(-۶/۵۵)	۰
-۶/۷۴	-۶/۷۹	-۶/۷۰	۱
(-۶/۵۹)	* (-۶/۷۱)	(-۶/۵۶)	۱
-۶/۷۰	-۶/۷۵	-۶/۶۴	۲
(-۶/۵۶)	(-۶/۶۲)	(-۶/۵۶)	۲

منبع: یافته‌های تحقیق (اعداد داخل پرانتز مربوط به آماره SBC است)

هیچ الگویی پیروی نمی‌کنند. بنابراین الگوهای فوق برای سری D(LGDP) الگوهای مناسبی به نظر می‌رسند. لذا با استفاده از این الگوها پیش‌بینی یک گام به جلو انجام می‌شود. با توجه به معیارهای مختلف، نتایج مربوط به میزان خطای پیش‌بینی در مدل ARIMA در جدول (۱۰) نشان داده شده است.

با توجه به معیارهای AIC و SBC، مدل (1,1,1) ARIMA جهت تخمین و پیش‌بینی انتخاب می‌شود. به منظور بررسی کفایت مدل‌های فوق، توابع خود همبستگی جزئی نمونه سری‌های باقیمانده‌ی حاصل مورد بررسی قرار می‌گیرد. مقادیر خودهمبستگی و خودهمبستگی جزئی نمونه همگی کوچک بوده و از

جدول (۱۱): میزان خطای پیش بینی با استفاده از معیارهای مختلف در روش ARIMA

RMSE	MAE	MAPE	معیار خطا	
			کشور	
۰/۰۰۴۵۰	۰/۰۰۳۴۵	۰/۴۷۲	آمریکا	
۰/۰۰۳۲۱	۰/۰۰۲۷۲	۰/۰۰۱۶۹	انگلستان	

منبع: یافته‌های تحقیق

## ۴.۶. مقایسه پیش‌بینی‌های صورت گرفته

در این قسمت به مقایسه‌ی پیش‌بینی‌های صورت گرفته با استفاده از روش‌های مختلف شبکه عصبی GMDH، شبکه عصبی MLFF (به عنوان روش‌های غیرخطی) و مدل ARIMA (به عنوان مدل خطی) پرداخته می‌شود.

جدول (۱۲) حاوی نتایج مربوط به خطاهای حاصل از پیش‌بینی GDP با استفاده از روش‌های مختلف در آمریکا است. هم‌چنین درصد تغییر RMSE و MAE نسبت به بهترین پیش‌بینی که همان شبکه عصبی GMDH با لحاظ وقفه‌های GDP و وقفه‌های نفت می‌باشد، محاسبه شده‌است.

جدول (۱۲): میزان RMSE، MAE و درصد تغییر آنها نسبت به بهترین پیش‌بینی در آمریکا

$\Delta$ MAE/%	MAE	$\Delta$ RMSE/%	RMSE	معیارهای خطای پیش‌بینی	
				روش‌های مختلف پیش‌بینی	
-----	۰/۰۰۳۱۰	-----	۰/۰۰۳۵۲	GMDH (با وقفه‌های GDP و نفت)	
۰/۹	۰/۰۰۳۳۸	۴/۵۴	۰/۰۰۳۶۸	GMDH (با وقفه‌های GDP)	
۱۱/۲۹	۰/۰۰۳۴۵	۲۷/۸۴	۰/۰۰۴۵۰	ARIMA	
۲۹/۰۳	۰/۰۰۴۰۰	۳۰/۱۱	۰/۰۰۴۵۸	MLFF (با وقفه‌های GDP و نفت)	
۲۹/۳۵	۰/۰۰۴۰۱	۳۳/۸۰	۰/۰۰۴۷۱	MLFF (با وقفه‌های GDP)	

منبع: یافته‌های تحقیق

این که نوسان‌های GDP در آمریکا غیرخطی است، مشاهده می‌شود که در این مورد شبکه عصبی GMDH بهترین پیش‌بینی را انجام داده‌است. درصد تغییرات RMSE در بدترین مدل، که مدل MLFF با لحاظ وقفه‌های GDP است، نسبت به بهترین مدل ۳۳/۸۰٪ است و

از نتایج به دست آمده مشخص می‌شود که روش GMDH با لحاظ وقفه‌های GDP و وقفه‌های نفت، کمترین خطای پیش‌بینی و روش MLFF با لحاظ وقفه‌های GDP دارای بیشترین میزان خطاست و سایر روش‌ها در بین این دو طیف قرار می‌گیرند. با توجه به

بهتری را در پیش‌بینی متغیر هدف نسبت به مورد مشابه در آمریکا ارائه می‌دهد. تفاوت اندک نتایج شبکه عصبی GMDH نسبت به ARIMA، بیانگر توانایی این روش غیرخطی در پیش‌بینی الگوهای خطی است. در جدول (۱۳) درصد تغییر RMSE و MAE نسبت به بهترین پیش‌بینی که همان روش ARIMA است، محاسبه شده است.

درصد تغییرات MAE در بدترین مدل نسبت به بهترین مدل ۲۹/۳۵٪ است.

جدول (۱۳) حاوی نتایج مربوط به خطاهای پیش‌بینی GDP با استفاده از روش‌های مختلف برای کشور انگلستان است. ملاحظه می‌شود که شبکه عصبی GMDH و روش خطی ARIMA کمترین خطای پیش‌بینی را، با تفاوتی اندک، دارند. از آنجایی که نوسان‌های GDP در انگلستان، از یک روند تقریباً خطی تبعیت می‌کند، بنابراین مدل خطی ARIMA عملکرد

جدول (۱۳): میزان MAE، RMSE و درصد تغییر آنها نسبت به بهترین پیش‌بینی در انگلستان

Δ MAE/	MAE	Δ RMSE/	RMSE	معیارهای خطای پیش‌بینی
				روش‌های مختلف پیش‌بینی
-----	۰/۰۰۲۷۰	-----	۰/۰۰۳۱۹	GMDH (باوقفه‌های GDP و نفت)
۰/۷۴	۰/۰۰۲۷۲	۰/۶۲	۰/۰۰۳۲۱	ARIMA
۱/۸۵	۰/۰۰۲۷۵	۶/۲۶	۰/۰۰۳۳۹	GMDH (با وقفه‌های GDP)
۲۲/۲۲	۰/۰۰۳۳۰	۱۰/۹۷	۰/۰۰۳۵۴	MLFF (با وقفه‌های GDP و نفت)
۲۴/۰۷	۰/۰۰۳۳۵	۱۹/۱۲	۰/۰۰۳۸۰	MLFF (با وقفه‌های GDP)

منبع: یافته‌های تحقیق

پیش‌بینی، از آماره‌های F، G-N و D-M استفاده می‌شود. آماره F به صورت زیر تعریف می‌شود:

$$F = \frac{\sum_{i=1}^h e_{1i}^2}{\sum_{i=1}^h e_{2i}^2}$$

برای انجام آزمون F سه فرض زیر در نظر گرفته می‌شود.

با توجه به نتایج به دست آمده در جدول بالا ملاحظه می‌گردد که درصد تغییر RMSE در بدترین مدل که مدل MLFF با لحاظ وقفه‌های GDP است، نسبت به بهترین مدل ۱۹/۱۲٪ است. هم‌چنین درصد تغییر MAE در بدترین مدل نسبت به بهترین مدل ۲۴/۰۷٪ است. در ادامه به منظور بررسی معنادار بودن تفاوت پیش‌بینی‌های صورت گرفته با بهترین



$$DM = \frac{\bar{d}}{\sqrt{\frac{\gamma_0 + 2\gamma_1 + \dots + 2\gamma_q}{H-1}}}$$

در سه آماره یاد شده فرضیه  $H_0$  عبارت از "پیش بینی ها تفاوت معنی داری با هم ندارند" است. در این بخش بهترین پیش بینی صورت گرفته در مورد آمریکا و انگلستان با سایر پیش بینی های صورت گرفته از لحاظ آماری مقایسه شده است. نتایج مقایسه پیش بینی ها که در جدول های (۱۴) و (۱۵) گزارش شده است، نشان می دهد که هیچ کدام از پیش بینی های صورت گرفته در مورد هر دو کشور از لحاظ آماری با هم تفاوت معنی داری ندارند. با توجه به این نتایج مشخص است که پیش بینی های صورت گرفته با استفاده از روش های مختلف از نظر آماری با هم تفاوت معنی داری ندارند.

۱- خطای پیش بینی میانگین صفر دارد و به صورت نرمال توزیع شده است.

۲- خطای پیش بینی به صورت سریالی ناهمبسته است.

۳- خطای پیش بینی ها با یکدیگر به صورت هم زمان ناهمبسته هستند.

گرنجر و نیوبلد (۱۹۷۶)<sup>۱</sup> به منظور مقایسه پیش بینی های انجام شده، آماره خود را به صورت زیر ارائه کردند.

$$x(t) = e_1(t) + e_2(t)$$

$$z(t) = e_1(t) - e_2(t)$$

$$GN = \frac{r_{xz}}{\sqrt{\frac{1 - r_{xy}^2}{H-1}}}$$

برای انجام آزمون گرنجر، دو فرض زیر در نظر گرفته می شود.

۱- خطای پیش بینی میانگین صفر دارد و به صورت نرمال توزیع شده است.

۲- خطای پیش بینی به صورت سریالی ناهمبسته می باشد.

دیبلد و ماریانا (۱۹۹۵)<sup>۲</sup> آماره D-M را جهت مقایسه پیش بینی های صورت گرفته، معرفی کردند. در این آماره الزاماً سه فرض محدود کننده آزمون F بر قرار نیست.

$$\bar{d} = \frac{1}{H} \sum_{t=1}^H [g(e_1(t)) - g(e_2(t))] ]$$

$$d(t) = g(e_1(t)) - g(e_2(t))$$

<sup>1</sup> Granger and New Bold

<sup>2</sup> Diebold and Mariano

**جدول (۱۴): بررسی معنادار بودن پیش‌بینی‌های صورت گرفته از بهترین پیش‌بینی در آمریکا**

			آماره‌های مقایسه پیش‌بینی
D-M	G-N	F	مقایسه روش‌های مختلف پیش‌بینی
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	GMDH (با وقفه‌های GDP و نفت) با MLFF (با وقفه‌های GDP و نفت)
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	GMDH (با وقفه‌های GDP و نفت) با GMDH (با وقفه‌های GDP)
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	GMDH (با وقفه‌های GDP و نفت) با MLFF (با وقفه‌های GDP)
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	GMDH (با وقفه‌های GDP و نفت) با ARIMA

منبع: یافته‌های تحقیق

**جدول (۱۵): بررسی معنادار بودن پیش‌بینی‌های صورت گرفته از بهترین پیش‌بینی در انگلستان**

			آماره‌های مقایسه پیش‌بینی
D-M	G-N	F	مقایسه روش‌های مختلف پیش‌بینی
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	ARIMA با GMDH (با وقفه‌های GDP و نفت)
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	ARIMA با GMDH (با وقفه‌های GDP)
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	ARIMA با MLFF (با وقفه‌های GDP و نفت)
$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	$H_0$ را نمی‌توان رد کرد	ARIMA با MLFF (با وقفه‌های GDP)

منبع: یافته‌های تحقیق

در این مطالعه با استفاده از شبکه عصبی GMDH و شبکه عصبی MLFF (به عنوان مدل‌های غیر خطی) به پیش‌بینی GDP با لحاظ وقفه‌های نفت و GDP و

### ۵. نتیجه گیری

به نوع اقتصادشان و هم چنین روابط تجاری آنها متفاوت است. به اعتقاد کارشناسان بزرگترین خطر برای اقتصاد متکی به نفت ایران در جریان رکود اقتصادی تغییرات قیمت نفت بر اثر همین رکود است. کاهش احتمالی قیمت نفت آثار منفی زیادی بر اقتصاد کشور خواهد گذاشت. با کاهش قیمت نفت، در آمد بودجه ای دولت از محل فروش دلارهای نفتی به شدت کاهش یافته و کسری بودجه شدیدی به وجود خواهد داشت. بنابراین پیش بینی این شرایط و اتخاذ سیاست مناسب کمک شایانی جهت کاهش اثرات ناشی از رکود احتمالی خواهد بود.

در این مطالعه برای پیش بینی GDP از روش های غیر خطی GMDH و MLFF و روش خطی ARIMA استفاده شد. در مطالعات آینده می توان از روش های غیر خطی دیگر مانند روش های غیر خطی اقتصادسنجی نیز استفاده کرد، که مقایسه نتایج حاصل از آن با شبکه های عصبی می تواند قابل تامل باشد. هم چنین در مطالعه صورت گرفته صرفاً به پیش بینی GDP با استفاده از قیمت های نفت پرداخته شد. بدیهی است که در مطالعات آینده می توان سایر متغیرهای اثر گذار بر GDP را نیز وارد الگو کرد و نتایج حاصل از پیش بینی آن را بهبود بخشید.

#### منابع

1. Abrishami, H. and M. Mehrara (2002), Applied Econometrics (New Approaches), Tehran: Tehran University Press.
2. Bayat, I. (1999) Accelerating Error Propagation Algorithm in Multi-layer Neural Networks Dynamic Parallel Tangent Algorithm, Thesis of Master in Computer,

هم چنین با لحاظ وقفه های GDP به تنهایی، پرداخته شد. سپس، نتایج به دست آمده با مدل ARIMA (به عنوان مدل خطی) مقایسه شد. نتایج در مورد آمریکا نشان می دهد که شبکه عصبی GMDH با لحاظ وقفه های GDP و وقفه های نفت، کمترین خطای پیش بینی و شبکه عصبی MLFF با لحاظ وقفه های GDP دارای بیشترین میزان خطا است و سایر روش ها در بین این دو طیف قرار می گیرند. در مورد انگلستان نیز نتایج نشان می دهد که شبکه عصبی GMDH با لحاظ وقفه های GDP و وقفه های نفت و روش ARIMA کمترین خطای پیش بینی و شبکه عصبی MLFF تنها با لحاظ وقفه های GDP دارای بیشترین میزان خطا است و میزان خطای سایر روش ها در بین این دو روش قرار می گیرد. لازم به ذکر می باشد که در مواردی که روابط بین متغیرها به صورت غیر خطی و پیچیده است، روش های غیر خطی نتایج بهتری را ارائه می کنند.

پیش بینی آثار تغییرات قیمت نفت خام بر تولید در آمریکا و انگلستان، رهنمون مناسبی جهت سیاست گذاری در کشور است. از آنجایی که اقتصادهای پیشرفته و بزرگی مانند آمریکا و انگلستان سهم عمده و بسزایی در تجارت بین الملل دارند، پیش بینی نوسان های تولید، رکود و رونق احتمالی تاثیر بسزایی بر اقتصاد کشور دارد. از آنجا که کشورها در دهکده جهانی علاوه بر ارتباطات فرهنگی و سیاسی با یکدیگر داد و ستد و ارتباط تجاری و اقتصادی نیز دارند، رکود اقتصادی در کشوری مانند آمریکا نمی تواند بر اقتصاد ایران بی تاثیر باشد. اما میزان این اثر گذاری و اثر پذیری در مورد کشورهای مختلف با توجه

14. Mory, J. F. (1993), "Oil Price and Economic Activity Is the Relation Symmetric," *Energy Journal*, 14 (4), 151-61.
15. Mrazban, H., R. Akbariyan And B. Javaheri (2006), "A Comparison Between Structural Econometrics Model, Time Series And Neural Network For Forecasting Exchange Rate," *Journal Of Tahghighat-E-Eghtesadi*, 69, 181-216.
16. Rodriligues , R. and M. Sanchez (2004), Oil Price Shocks and Real GDP Growth; Empirical Evidence for some OECD Countries", Working paper, N362 .
17. www.bea.org
18. www.bp.com
19. www.eia.doe.gov
20. www.nymex.com
21. www.statistics.gov.uk
3. Diebold, F. X. and R. S. Mariano (1995), "Comparing Predictive Accuracy," *Journal of Business and Economic Statistics*, 13(3), 253-263.
4. Fujimoto, K. and S. Nakabayashi (2003) "Applying GMDH Algorithm to Extract Rules from Examples," *Systems Analysis Modeling Simulation*, 43(10), 1311-1319.
5. Granger, C., and p. Newbold (1974), "Spurious Regression in Econometrics," *Journal of Econometrics*, 2, 111-120.
6. Gujarati, D. N. ( 2008), Essentials of Econometrics, Translated by. Hamid Abrishami, Tehran: Tehran University Press.
7. Hamilton, J. (1983), "Oil and the Macro Economy since World War II," *Journal of Political Economy*, 91 (2), 228- 248.
8. Hamilton, J. (1996) ,"This is what happened to the oil price – macro economy relationship", *Journal of monetary economics*, 38 (2), 215-20.
9. Hamilton, J.(2003) ,"What is an oil shock?", *Journal of Econometrics*, 113 (2), 363-398.
10. Ivakhnenko, A., G. Yu, V. Kostenko and I. V. Goleusov (1983), "Systems Aanalysis and Long-term Quantitative Prediction of Quasi-static Systems on the Basis of Self-Organization of Models," Part 2, Objective Systems Analysis without a Priori Specification of External Influences, *Soviet Automatic Control c/c of Avtomatika*, 16 (3), 1-8.
11. Lemke, F. and J. A. Muller (1997), Self-organizing Modeling in Financial Risk Control, Proceedings of the 15<sup>th</sup> IMACS World Congress on Scientific Computation, Modeling and Applied Mathematics, 6, 733-738.
12. Malik, F. and M, Nasereddin (2006), "Forecasting Output Using Oil Price: A Cascaded Artificial Neural Network Approach," *Journal of Economics and Business*, 58(2), 168-180
13. Moradi. A. (2005), Application of EVIEWS in Econometrics, Tehran: Jahad-e-Daneshgahi.