

## پیش‌بینی بی‌ثباتی قیمت نفت با استفاده از شبکه‌ی عصبی GMDH

محسن مهرآرا

دانشیار دانشکده‌ی اقتصاد دانشگاه تهران،  
[mehrara@ut.ac.ir](mailto:mehrara@ut.ac.ir)

نفیسه بهروادمهر

مدرس دانشکده اقتصاد دانشگاه تهران،  
[nbehradmehr@yahoo.com](mailto:nbehradmehr@yahoo.com)

مهدی احراری

پژوهشگر اقتصادی،  
[meahrari@yahoo.com](mailto:meahrari@yahoo.com)

محسن محقق

دانشجوی کارشناسی ارشد اقتصاد، دانشگاه تهران،  
[mmohaghegh@ut.ac.ir](mailto:mmohaghegh@ut.ac.ir)

تاریخ دریافت: ۸۸/۱۲/۲۲ تاریخ پذیرش: ۸۹/۴/۲۶

### چکیده

بی‌ثباتی قیمت نفت، از یک سو به عنوان یکی از مؤلفه‌های تأثیرگذار در الگوهای اقتصاد کلان و از سوی دیگر به عنوان یکی از متغیرهای اساسی در الگوهای مدیریت ریسک و الگوهای گزینش پورتفوی، همواره مورد توجه پژوهش‌گران بوده است. مقاله‌ی حاضر می‌کوشد تا با استفاده از شبکه‌های عصبی، الگویی برای پیش‌بینی بی‌ثباتی قیمت نفت ارائه دهد. به این منظور، بی‌ثباتی قیمت نفت خام برنت و وست تگزاس اینترمدیت پیش‌بینی شده است. مقایسه‌ی نتایج حاصل از چهار الگوی مورد بررسی، شامل الگوی اقتصادسنجی GARCH(1,1)، دو نوع الگوی مبتنی بر شبکه‌ی عصبی GMDH و الگوی ترکیبی شبکه‌ی عصبی GMDH و GARCH(1,1)، نشان می‌دهد که الگوی ترکیبی و شبکه‌های عصبی بر مبنای معیار جذر میانگین مربع خطای پیش‌بینی (RMSE) برای هر دو سری، پیش‌بینی بهتری را نسبت به الگوی اقتصادسنجی GARCH(1,1) ارائه می‌دهند.

**JEL طبقه‌بندی:** Q47, C14, C15, C45, C53, C67, G17

**کلید واژه:** بی‌ثباتی، شبکه‌ی عصبی GMDH، روش‌های خودرگرسیون واریانس ناهمسان شرطی (ARCH)

## ۱- مقدمه

نفت، بی‌تردید از مهم‌ترین نهاده‌های تولید است که هرگونه تغییر در شاخص‌های بازاری آن نظریه قیمت یا بی‌ثباتی<sup>۱</sup>، تقریباً تمامی کشورهای تولیدکننده و صادرکننده‌ی نفت را متأثر می‌کند. شوک‌های بازار نفت را می‌توان از نظر تأثیرات اقتصادی، حتی فراتر از شوک‌های دیگر بازارهای مالی به شمار آورد، چراکه برای مثال، افزایش قیمت نفت به کاهش تقاضای انرژی و در نتیجه پایین آمدن بهره‌وری سرمایه می‌انجامد؛ پدیده‌ای که با فرض ثبات دستمزد اسمی، افزایش بیکاری را به دنبال خواهد داشت. این البته، تنها یکی از پیامدهای پرشمار و گستردگی شوک‌های نفتی است. در ادامه و در پیشینه‌ی پژوهش به برخی از مطالعاتی اشاره می‌کنیم که اساساً به موضوع آثار شوک‌های نفتی بر متغیرهای اقتصادی پرداخته‌اند. همین اهمیت و گستردگی پیامدها، توجه بسیاری را به تحلیل بازارهای نفت معطوف کرده است.

از سوی دیگر، بازار نفت، همواره بازاری متلاطم و سرشار از رویدادهای پیش‌بینی ناپذیر بوده است. مرور تغییرات قیمت نفت در دهه‌های گذشته و موقع چندین شوک نفتی بزرگ، به خوبی گویای این واقعیت است. اما این امر، نه تنها انگیزه‌ی پژوهش‌گران را برای پیش‌بینی بازار نفت کاهش نداده، بلکه به گواه شمار فراوان پژوهش‌های این حوزه، حتی بستری برای تلاش‌های بدیع و ارائه‌ی الگوهای تازه نیز بوده است. پیش‌بینی درست شاخص‌های بازاری نفت، هم برای بنگاه‌های اقتصادی و هم برای دولتها از اهمیت بسیار بالایی برخوردار است؛ یادآوری این نکته که کشور ایران به عنوان یکی از کشورهای صادرکننده‌ی نفت، برای تأمین هزینه‌های دولت تا حد زیادی به درآمدات این مستقیم و غیرمستقیم نفتی وابسته است، اهمیتِ دوچندان این موضوع را برای کشور ما بهتر نمایان می‌کند.

مسیر تغییرات قیمت نفت نیز هم‌چون قیمت دیگر دارایی‌ها، تحت فرضیه‌ی بازارهای کارآمد، نوعی گام تصادفی است و به همین دلیل بهترین پیش‌بینی آن، قیمت دوره‌ی (روز) گذشته خواهد بود. در چنین شرایطی، پیش‌بینی بی‌ثباتی نقش بهسزایی در تصمیم‌گیری فعالان اقتصادی خواهد داشت. بی‌ثباتی که معمولاً به صورت واریانس شناخته می‌شود، شاخصی برای تخمین دامنه‌ی نوسانات قیمت در دوره‌های آتی است و

1- Volatility.

شاید به همین دلیل، پیش‌بینی بی‌ثباتی، سهم قابل توجهی از مطالعات مربوط به بازارهای مالی مختلف را به خود اختصاص می‌دهد. مطالعه‌ی حاضر نیز بخشی از این ادبیات گسترده به شمار می‌آید. در این مطالعه برآینم تا با استفاده از شبکه‌ی عصبی GMDH، بی‌ثباتی قیمت نفت را پیش‌بینی کنیم.

پس از نگاهی گذرا به پیشینه‌ی پژوهش در بخش دوم مقاله، در ادامه و در بخش سوم به معروفی اجمالی شبکه‌های عصبی و به طور ویژه، شبکه‌ی موردن استفاده در این مقاله می‌پردازیم. در بخش چهارم داده‌های به کار گرفته شده در مقاله و ویژگی‌های آماری آن‌ها را بررسی خواهیم کرد. در پایان این بخش، نتایج تجربی حاصل از این مطالعه ارائه خواهند شد و در نهایت، در بخش پایانی مقاله به نتیجه‌گیری و ارائه‌ی پیشنهادات می‌پردازیم.

## ۲- پیشینه‌ی پژوهش

نگاهی گذرا به ادبیات موضوع، نشان می‌دهد که هم در سطح بین‌المللی و هم در سطح داخلی، به ویژه پس از مقاله‌ی هامیلتون<sup>(۱)</sup> (۱۹۸۳)، مطالعات فراوانی در رابطه با آثار تغییر قیمت نفت بر متغیرهای حقیقی اقتصاد انجام گرفته است. برای مثال، کولونی و مانرا<sup>(۲)</sup> (۲۰۰۸)، در مطالعه‌ای با استفاده از یک مدل خودرگرسیو برداری همانباشته<sup>(۳)</sup> به بررسی رابطه‌ی میان قیمت نفت، نرخ تورم و نرخ بهره در هفت کشور صنعتی جهان پرداخته‌اند. آن‌ها نشان می‌دهند که تقریباً در تمامی کشورهای صنعتی (به جز ژاپن و انگلستان)، فرضیه‌ی وجود رابطه میان قیمت نفت و نرخ تورم را نمی‌توان رد کرد و شوک‌های تورمی نیز از طریق تأثیر بر نرخ بهره به بخش حقیقی اقتصاد منتقل می‌شوند. ژانگ<sup>(۴)</sup> (۲۰۰۸)، با استفاده از رویکردی غیرخطی، رابطه‌ی تغییرات قیمت نفت و رشد اقتصادی در ژاپن را بررسی کرده و نشان داده است که میان این دو متغیر رابطه‌ای غیرخطی وجود دارد. هوانگ و همکاران<sup>(۵)</sup> (۲۰۰۵)، برای مطالعه‌ی چگونگی اثرات تغییرات قیمت و بی‌ثباتی نفت بر اقتصاد کشورهای ژاپن، کانادا و امریکا، از الگوی

1- Cologni and Manera .

2- Cointegrated Vector Auto Regressive (VAR) .

3- Zhang .

4- Huang et al.

آستانه‌ای چندمتغیره بهره گرفته‌اند. آن‌ها به این نتیجه رسیده‌اند که اگر تغییر در سطح قیمت یا بی‌ثباتی، پایین‌تر از آستانه‌ی مورد نظر باشد، اثری محدود بر متغیرهای اقتصادی خواهد داشت، اما اگر این میزان بیش از حد آستانه باشد، تغییرات قیمت یا بی‌ثباتی، حتی بهتر و بیش‌تر از تغییرات نرخ بهره‌ی واقعی، متغیرهای اقتصادی را توضیح می‌دهند و بالاخره لاردیک و میگنون<sup>۱</sup> (۲۰۰۶)، وجود رابطه‌ی بلندمدت میان قیمت نفت و تولید ناخالص داخلی (GDP) را در ۱۲ کشور اروپایی آزمون کردند. آن‌ها در مطالعه‌ی مشابهی (۲۰۰۸) همین مسئله را برای بسیاری از کشورهای اروپایی، کشورهای عضو منطقه‌ی یورو و کشورهای عضو گروه هفت، بررسی کردند و در هر دو مورد، مطالعه‌ی آن‌ها وجود نوعی همانباشتگی نامتقارن را میان قیمت نفت و تولید ناخالص داخلی کشورها تأیید می‌کند.

در سطح داخلی نیز مطالعات فراوانی در این زمینه دیده می‌شود؛ برای نمونه، ابریشمی و همکاران (۱۳۸۷)، اثر نوسانات قیمت نفت بر رشد اقتصادی برخی کشورهای عضو سازمان توسعه و همکاری اقتصادی (OECD) را با استفاده از تصریح غیرخطی قیمت نفت به روش GARCH در قالب یک دستگاه VECM مورد مطالعه قرار دادند. نتایج آن‌ها نشان می‌دهد که نوسانات مثبت و منفی قیمت نفت اثرات نامتقارنی بر رشد اقتصادی دارند؛ به علاوه، آن‌ها دریافته‌اند که شوک پولی در کنار شوک قیمت نفت، عوامل مؤثری در بی‌ثباتی رشد GDP به شمار می‌آیند. درباره‌ی آثار تغییر قیمت نفت بر اقتصاد ایران نیز مطالعات فراوانی انجام گرفته است، که برای نمونه فقط به مطالعه‌ی فرزانگان و مارکوارت<sup>۲</sup> (۲۰۰۹) اشاره می‌شود. آن‌ها با استفاده از مدل خودرگرسیون برداری، رابطه‌ی پویای نوسانات قیمت نفت و متغیرهای اقتصاد کلان ایران مانند تورم، نرخ رشد تولیدات صنعتی و مخارج حقیقی دولت را بررسی کردند. اما به تدریج، بررسی‌ها نشان داد که افزون بر تغییر در سطح قیمت، تغییر در بی‌ثباتی قیمت نفت نیز می‌تواند پیامدهای اقتصادی قابل توجهی داشته باشد. برای مثال فردرر<sup>۳</sup>، رابطه‌ی بی‌ثباتی قیمت نفت و اثرات آن بر اقتصاد کلان را موضوع مطالعه‌ی خود قرار

1- Lardic and Mignon .

2- Farzanegan and Mrakwardt.

3- Ferderer .

داده است. یوری<sup>۱</sup> (۱۹۹۵)، به بررسی رابطه‌ی بی‌ثباتی قیمت نفت و نرخ بیکاری در اقتصاد آمریکا و به ویژه بیکاری بخش کشاورزی (یوری، ۱۹۹۶) این کشور می‌پردازد. رفیق و همکاران<sup>۲</sup> (۲۰۰۹) نیز، تأثیر بی‌ثباتی قیمت نفت بر متغیرهای کلان اقتصادی را در کشور تایلند بررسی کرده و نشان داده‌اند که اثر چشم‌گیری بر شاخص‌های عمدی دارد. اساساً بی‌ثباتی قیمت نفت، علاوه بر تأثیر در شاخص‌های اقتصادی، در فرایندهای مدیریت ریسک و الگوهای گزینش پورتفولیو نیز نقشی حیاتی دارد.

در مجموع پژوهش‌های نام برده شده نشان می‌دهند که تغییر در قیمت و نیز بی‌ثباتی در بازار نفت، می‌تواند پیامدهای گسترده‌ای در اقتصاد کشورهای تولیدکننده و واردکننده‌ی نفت داشته باشد. از این نظر می‌توان این مطالعات را مبانی نظری ارائه شده برای توجیه ضرورت پیش‌بینی قیمت و بی‌ثباتی بازار نفت به شمار آورد. در ادامه نمونه‌ای از پژوهش‌های انجام گرفته در حوزه‌ی پیش‌بینی شاخص‌های بازاری نفت بررسی خواهد شد. بی‌تردید، مطالعات به انجام رسیده در این حوزه پرشمارند، اما با توجه به موضوع و هدف مقاله، که پیش‌بینی بی‌ثباتی با استفاده از شبکه‌های عصبی و روش‌های داده‌مبناست، در این بخش به سه گروه از پژوهش‌هایی که بر پایه‌ی پیش‌تری با موضوع مقاله دارند، خواهیم پرداخت؛ نخست، پژوهش‌هایی که بر پایه‌ی خانواده‌ی روش‌های هوش مصنوعی در صدد پیش‌بینی قیمت نفت برآمده‌اند. دسته‌ی دوم آن‌هایی که بی‌ثباتی را با استفاده از شبکه‌های عصبی، اما در بازارهای دیگری غیر از بازار نفت (به ویژه بازار سهام) پیش‌بینی کرده‌اند و دسته‌ی سوم، پژوهش‌هایی که بی‌ثباتی را در بازار نفت اما با استفاده از روش‌های اقتصادسنجی مطالعه کرده‌اند. مطالعه‌ی پیش‌رو، در مرز دو دسته‌ی پایانی گام بر می‌دارد، به عبارت بهتر این مقاله می‌کوشد تا بی‌ثباتی در بازار نفت را به کمک شبکه‌ی عصبی پیش‌بینی کند.

بازار نفت‌خام نیز هم‌چون بازار دیگر دارایی‌ها، بنا به فرض، از الگوی گام تصادفی پیروی می‌کند؛ به همین دلیل و با در نظر گرفتن آثار اقتصادی پیش‌گفته، ارائه‌ی الگوهایی برای پیش‌بینی شاخص‌های عمدی بازار نفت همواره مورد توجه پژوهش‌گران بوده است. بیش‌تر روش‌های موسوم به هوش مصنوعی و به ویژه شبکه‌های عصبی،

1- Uri .

2- Rafiq et al.

به دلیل رویکرد مبتنی بر داده و ماهیت غیرخطی خود (خاشعی و بیجاری<sup>۱</sup>، ۲۰۱۰) ابزارهایی قدرتمند در حوزه‌ی پیش‌بینی محسوب می‌شوند؛ شبکه‌های عصبی به دلیل همین توانایی، به ویژه در دهه‌های اخیر بسیار مورد توجه قرار گرفته‌اند و مقاله‌های فراوانی بر پایه‌ی آن‌ها در نشریات معتبر علمی داخلی و بین‌المللی منتشر شده است. برای نمونه، کولکارنی و حیدر<sup>۲</sup> (۲۰۰۹)، یو و همکاران<sup>۳</sup> (۲۰۰۸)، فرجامنیا و همکاران (۱۳۸۶) و اصفهانیان و ناصری (۱۳۸۷)، به پیش‌بینی قیمت نفت با استفاده از گونه‌ها و ترکیب‌های مختلف شبکه‌های عصبی پرداخته‌اند. غفاری و زارع<sup>۴</sup> (۲۰۰۹)، نیز با استفاده از سیستم استنتاج فازی انطباق‌پذیر مبتنی بر شبکه<sup>۵</sup>، قیمت نفت وست تگزاس اینترمدیت (WTI) را پیش‌بینی کرده‌اند.

به عنوان دسته‌ی دوم می‌توان از مطالعات پرشماری یاد کرد که در حوزه‌ی بی‌ثباتی در بازارهای سهام به انجام رسیده‌اند و در آن‌ها از شبکه‌های عصبی برای پیش‌بینی بی‌ثباتی بهره گرفته شده است. برای مثال حمید و اقبال<sup>۶</sup> (۲۰۰۴)، با استفاده از شبکه‌های عصبی، به پیش‌بینی بی‌ثباتی شاخص سهام S&P پرداخته‌اند. دونالدسون و کامسترا<sup>۷</sup> (۱۹۹۷) و روه<sup>۸</sup> (۲۰۰۷)، مدل‌هایی ترکیبی از شبکه‌های عصبی و روش‌های خانواده‌ی روش‌های خودرگرسیون واریانس ناهمسان شرطی (ARCH) برای پیش‌بینی بی‌ثباتی در بازارهای سهام ارائه داده‌اند و بالاخره تیسنگ و همکاران<sup>۹</sup> (۲۰۰۸)، و بیلدریچی و ارسین<sup>۱۰</sup> (۲۰۰۹) نیز مطالعات مشابهی را به شکل موردنگاری<sup>۱۱</sup>، به ترتیب برای بازار سهام تایوان و ترکیه به انجام رسانده‌اند. اما در حوزه‌ی بی‌ثباتی قیمت نفت، تقریباً تمامی مطالعات داخلی و خارجی از خانواده‌ی روش‌های خودرگرسیوی واریانس ناهمسان شرطی (ARCH) برای پیش‌بینی بی‌ثباتی استفاده کرده‌اند؛ از جمله مطالعات

1- Khashei and Bijari.

2- Kulkarni and Haidar.

3- Yu et al.

4- Gaffari &amp; Zare .

5- Adaptive Network-based Fuzzy Inference System (ANFIS).

6- Hamid and&amp; Iqbal.

7- Donaldson and Kamstra.

8- Roh.

9- Tseng et al.

10- Bildirici and Ersin.

11- Case Study.

بین‌الملی این دسته می‌توان به سادورسکی<sup>۱</sup> (۲۰۰۶)، نارایان و نارایان<sup>۲</sup> (۲۰۰۷)، آنولوچی<sup>۳</sup> (۲۰۰۹)، کنگ و همکاران<sup>۴</sup> (۲۰۰۹)، و چیونگ<sup>۵</sup> (۲۰۰۹) و از مطالعات داخلی نیز می‌توان به ابریشمی، مهرآرا و آریانا<sup>۶</sup> (۱۳۸۶)، اشاره کرد. تمامی این مطالعات به بررسی و مقایسه‌ی مدل‌های مختلف ارایه شده در این خانواده پرداخته‌اند و در نهایت بر حسب نمونه و اهداف مطالعه‌ی خود، الگویی را که کمترین خطای را در پیش‌بینی داشته است، به عنوان بهترین الگویی پیش‌بینی معرفی کرده‌اند. الگوهای خانواده‌ی روش‌های خودرگرسیوی واریانس ناهمسان شرطی (ARCH)، گرچه در برآورد بی‌ثباتی بازدهی دارایی‌های مالی، عملکرد قابل قبولی داشته‌اند، اما نتایج آن‌ها در پیش‌بینی بی‌ثباتی چندان جالب توجه نبوده است. (برای مثال، می‌توان از بولرسلو و وولدریج<sup>۷</sup> (۱۹۹۲) و پون و گرنجر<sup>۸</sup> (۲۰۰۳) نام برد). به عبارت بهتر، مدل‌های ARCH در پیش‌بینی‌های برون نمونه‌ای به اندازه‌ی برآوردهای درون‌نمونه‌ای مؤفق عمل نمی‌کنند (آنولوچی، ۲۰۰۹)، همین امر می‌تواند توجیه مناسبی برای استفاده از روش‌های داده مینا در پیش‌بینی بی‌ثباتی به شمار آید.

### ۳- شبکه‌ی عصبی GMDH<sup>۹</sup> و بهینه‌سازی چند منظوره‌ی پارتو

در سال‌های اخیر روش‌شناسی شبکه‌ی عصبی به عنوان رقیبی برای متداول‌وزی‌های سنتی آماری ظهر کرده است (وست<sup>۱۰</sup>، ۲۰۰۰). این شبکه‌ها، مبتنی بر شبیه‌سازی‌های کامپیوتربی از نمونه‌های عصبی هستند و با استفاده از یک پایه‌ی ریاضیاتی اعمال خود را انجام می‌دهند. ایده‌ی اصلی این روش عبارتست از طراحی یک مدل بهینه‌ی پیچیده، که فقط مدل را بر پایه‌ی داده‌ها و اطلاعات طراحی کند و هیچ‌گونه پیش‌زمینه‌ی نظری از نحوه‌ی عملکرد داده‌ها از سوی محقق انجام نگیرد و این کار تنها بر اساس کشف

1- Sadorsky.

2- Narayan and Narayan.

3- Agnolucci.

4- Kang et al.

5- Cheong.

6- Bollerslev and Wooldridge .

7- Poon and Granger .

8- Group Method of Data Handling.

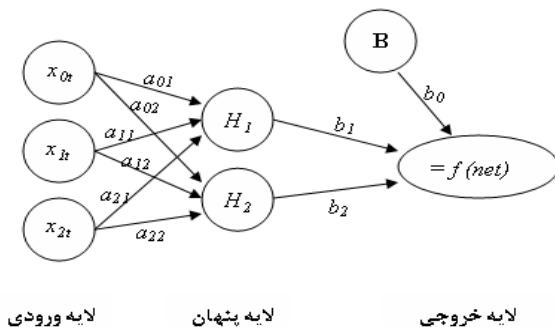
9- West.

ارتباط ساده و پیچیده میان داده‌های ورودی و خروجی سیستم انجام گیرد، بنابراین یک مدل خودتنظیم کننده خواهد ساخت که قابلیت حل مسائل پیش‌بینی، تشخیص، ترکیبات کنترلی و سایر مسائل سیستمی به کار بردشده را دارد.

شبکه‌ی عصبی عبارت از یک سیستم ورودی – خروجی است که پردازش اطلاعات توسط لایه‌های پنهان انجام می‌گیرد، بنابراین هر سیستم ورودی – خروجی با سازه‌ی شبکه‌ی عصبی دارای اجزای ذیل است:

- ۱- لایه‌ی ورودی: شامل بردار متغیرهای مستقل
- ۲- لایه‌های پنهان: شامل توابع عملگر، نرون‌های پردازش کننده‌ی داده‌های ورودی
- ۳- لایه‌ی خروجی: شامل برآورد (پیش‌بینی) بردار متغیر هدف (وابسته)

شکل (۱) سازه شبکه‌ی عصبی با یک لایه‌ی پنهان را نشان می‌دهد.



شکل ۱- شبکه‌ی عصبی با یک لایه‌ی پنهان

در ادبیات شبکه‌ی عصبی، به جای اصطلاح تخمین ضرایب، از اصطلاح یادگیری یا آموزش برای پیدا کردن ارزش وزن‌های شبکه استفاده می‌شود. هدف، کمینه کردن مجموع مربعات خطای یعنی اختلافات میان ارزش‌های خروجی هدف و خروجی برآشش شده از شبکه‌ی عصبی می‌باشد.

بدین منظور داده‌ها را به دو مجموعه‌ی زیر تقسیم می‌کنند:

- ۱- آموزش<sup>۱</sup>: الگوسازی و شبیه‌سازی (۷۰٪ داده‌ها را شامل می‌شود)

1- Train.

## ۲- آزمون<sup>۱</sup> : پیش‌بینی (۳۰٪ داده‌ها را شامل می‌شود)

برخلاف مدل‌سازی تحلیلی و تئوریک که در آن تمامی اجزای سیستم معرفی شده و تنها لازم است که ارتباط اجزاء را برقرار و تجزیه و تحلیلی از کل مجموعه انجام شود، در مدل‌سازی عددی، اجزای سیستم مجھول بوده و تنها ورودی و خروجی آن در دسترس می‌باشد. در مدل‌سازی عددی مبتنی بر شناسایی<sup>۲</sup> سیستم، تلاش داریم که با استفاده از اطلاعات ورودی و خروجی آن را شناسایی کنیم، که حاصل این شناسایی با ایجاد یکتابع تقریبی ریاضی میان ورودی و خروجی که همان مدل سیستم می‌باشد، توان است.

روش دسته‌بندی گروهی داده‌های عددی، یک فناوری آموزش آماری برای غلبه بر ضعف‌های آماری و شبکه‌های عصبی است. آن‌چه الگوریتم GMDH را به عنوان یک روش هیوریستیک<sup>۳</sup> معرفی می‌کند، ساختن مدل‌هایی برای سیستم‌های پیچیده از نوع رگرسیون با درجات بالا می‌باشد که دارای مزایایی نسبت به مدل‌سازی کلاسیک است. اولین بار الگوریتم GMDH توسط یک دانشمند اوکراینی به نام ایواخننکو<sup>۴</sup> (۱۹۶۸)، معرفی شد.

به طور کلی دو دیدگاه اصلی در معرفی و شناخت شبکه‌های عصبی وجود دارد (درویزه و همکاران<sup>۵</sup>، ۲۰۰۱). در دیدگاه اول؛ شبکه‌های عصبی را می‌توان علمی قلمداد کرد که دارای انواع مختلف ساختار شبکه‌ای بوده و از توانایی بالایی در شناسایی و مدل‌سازی برخوردار است. پایه و اساس این دیدگاه، آموزش شبکه‌های عصبی است. در دیدگاه دوم؛ شبکه‌های عصبی به عنوان یک ابزار علمی برای پیاده‌سازی و تفهیم الگوریتم‌ها قرار می‌گیرند و یا به عبارتی در این دیدگاه شبکه‌های عصبی، فلورچارتی برای الگوریتم‌های پیچیده ریاضی می‌باشد در مورد شبکه‌های عصبی GMDH با دیدگاه دوم باید به قضیه نگریست. به طور کلی الگوریتم GMDH را نیز می‌توان از دو نظر

1- Test.

2- Identification.

3- الگوریتم هیوریستیک (Heuristic)، عبارت است از معیار، روش و یا اصولی برای تصمیم‌گیری بین چندین خطا مشی، به طوری که اثربخش‌ترین آنان برای دست‌یابی به اهداف موردنظر، انتخاب شود.

4- Ivakhnenko

5- Darvizeh et al.

متفاوت مورد بحث و بررسی قرار داد؛ در قسمت اول، این الگوریتم را بر اساس مبنای ریاضی آن و در قسمت دوم، بر اساس تئوری و آنالیز مدل‌سازی سیستم معرفی کرد.  
بر مبنای ریاضی الگوریتم GMDH، بر اساس تجزیه‌ی سری توابع ولترا<sup>۱</sup> به چند جمله‌ای‌های دو متغیره‌ی درجه‌ی دوم پایه‌ریزی شده است.

$$G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j$$

در این تجزیه، سری ولترا به مجموعه‌ای از معادلات بازگشتی زنجیره‌ای تبدیل می‌شود، به گونه‌ای که دوباره با جای‌گذاری جبری هر یک از روابط بازگشتی در یکدیگر، سری ولترا برقرار شود. الگوریتم GMDH در قسمت دوم بر اساس تئوری و آنالیز مدل‌سازی سیستم‌هاست، این مدل‌سازی بر اساس دو قاعده‌ی کلی بنا می‌شود (دولنکو و همکاران<sup>۲</sup>، ۱۹۹۶ و واسچکینا و یارین<sup>۳</sup>، ۲۰۰۱).

سیستم‌های پیچیده‌ای که شامل  $m$  متغیر ورودی و یک خروجی باشند را می‌توان به تعداد  $C_m^m = \frac{m(m-1)}{2}$  سیستم جزئی<sup>۴</sup> ساده‌ای که دارای دو ورودی و یک خروجی است، تجزیه کرد، البته خروجی تمامی سیستم‌های جزئی، یکسان و همانند خروجی سیستم اصلی در نظر گرفته می‌شود.

برای ترکیب دو سیستم جزئی در قالب یک سیستم واحد و تشکیل سیستم جزئی جدید دیگری که متغیرهای هر دو سیستم قبلی را در بر می‌گیرد، کافیست که خروجی یا مقادیر تخمین زده‌ی هر دو مدل به دست آمده را به ازای  $n$  نمونه‌ی ورودی دوباره مدل کنیم. الگوریتم GMDH، با به کار بستن این دو قاعده در دستور کار خود عمل مدل‌سازی را انجام می‌دهد، هدفی را که همواره در پروسه ترکیب مدل‌های به وجود آمده مدنظر است، دست یافتن به مدل‌هایست که تقریباً تمامی متغیرهای سیستم در آن نمایان و نقش داشته باشند، هدف دیگر رسیدن به مدلی است که میزان خطای خروجی آن نسبت به سایر مدل‌های محاسبه شده در مراحل قبل کمتر باشد (منهاج، ۱۳۷۹).

1- Volterra.

2- Dolenko et al.

3- Vasechkina &amp; Yarin.

4- Partial System.

شبکه‌های عصبی GMDH جلوه‌ای از الگوریتم GMDH می‌باشد که به فرم و ساختار شبکه‌ای بیان شده است. شبکه‌ی عصبی GMDH، شبکه‌ای خود سامانده و یک سویه می‌باشد که از چند لایه و هر لایه نیز از چندین نرون تشکیل یافته است، تمامی نرون‌ها از یک ساختار مشابه برخوردارند. وزن‌ها ( $w$ )، براساس روش‌های تجزیه‌ی مقادیر منفرد (SVD<sup>۱</sup>) و حل معادلات متعامد (SNE<sup>۲</sup>) به عنوان مقادیر مشخص و ثابت در داخل هر نرون جای‌گذاری می‌شود. ویژگی بارزی که در این نوع از شبکه‌ها مشاهده می‌شود، نشان می‌دهد که نرون‌های مرحله‌ی قبلی و یا لایه‌ی قبلی ( $m$ )، عامل و یا مولد تولید نرون‌های جدید به تعداد  $C_m^2$  هستند. از میان نرون‌های تولید شده لزوماً بایستی تعدادی از آن‌ها حذف شود تا بدین وسیله از واگرایی شبکه جلوگیری به عمل آید، اصلاحاً به این‌گونه نرون‌ها، نرون‌های مرده گفته می‌شود (Lemke, ۱۹۹۷).

روش‌های تکاملی<sup>۳</sup> مانند الگوریتم ژنتیک کاربرد وسیعی در مراحل مختلف طراحی شبکه‌های عصبی دارند (واسچکینا و یارین، ۲۰۰۱) چنان که دارای قابلیت‌های منحصر به فردی در پیدا کردن مقادیر بهینه و امکان جستجو در فضاهای غیرقابل پیش‌بینی هستند. در تحقیق حاضر، برای طراحی شبکه‌ی عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شده است (Jamali و همکاران، ۲۰۰۶).

یکی از کاستی‌های شبکه‌های عصبی در پیش‌بینی بی‌ثباتی این است که یافته‌های برآمده از شبکه بر پایه‌ی هیچ‌یک از الگوهای اقتصادسنجی استوار نشده‌اند و به عبارت بهتر، این نتایج را نمی‌توان با استفاده از ادبیات اقتصادسنجی اثبات کرد. به علاوه، ورودی‌های شبکه به عنوان مهم‌ترین عامل تأثیرگذار در بهبود پیش‌بینی‌ها، طی فرایندی مستمر و از طریق سعی و خطابه دست می‌آیند (روه، ۲۰۰۷). با این همه، به کارگیری شبکه‌های عصبی، اگر با مهارت کاربر و گزینش مناسب ورودی‌ها توأم باشد، اغلب به پیش‌بینی‌هایی بهتر از پیش‌بینی الگوهای متدائل اقتصادسنجی می‌انجامد. افزون بر این، استفاده از الگوهای ترکیبی که در ادبیات پیش‌بینی به سرعت در حال گسترش است، تلاشی برای برطرف کردن کاستی‌های پیش‌گفته به شمار

1- Singular Value Decomposition.

2- Solving Normal Equation.

3- Lemke.

4- Evolutionary.

5- Jamali et al.

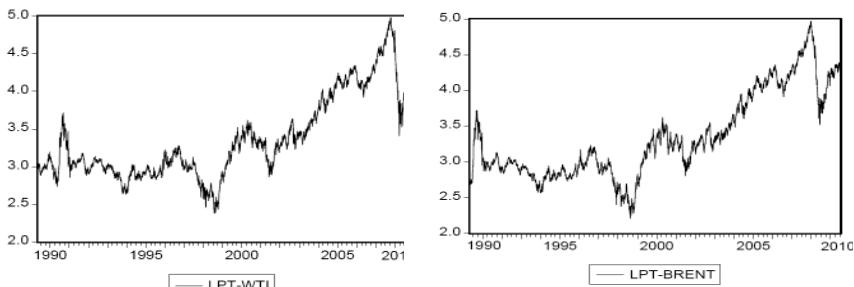
می آید. در این قبیل الگوها، ورودی شبکه با استفاده از الگوهای اقتصادسنجی تعیین می شود. به این ترتیب دیگر به فرایند تکراری سعی و خطای برای یافتن ورودی ها نیازی نخواهد بود. به علاوه، گاه چندین ورودی مهم در قالب الگوی اقتصادسنجی به یک متغیر وزن دار تبدیل می شوند، که این امر، بر کارایی شبکه های عصبی نیز می افزاید (روه، ۲۰۰۷).

#### ۴- نتایج تجربی

در این بخش ابتدا داده های تحقیق، ارائه و پس از بررسی مانایی آن ها نتایج تجربی براساس الگوهای مورد بررسی، استخراج می شود و در نهایت مورد تجزیه و تحلیل قرار می گیرد.  
داده ها

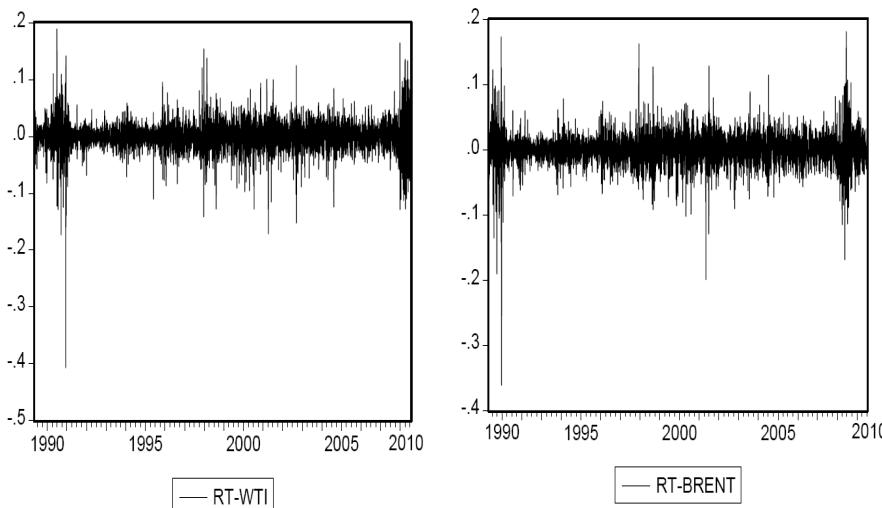
در این مقاله از اطلاعات مربوط به قیمت های روزانه نفت و سنتگراس اینترمیدیت (WTI) و نیز نفت برنت در دوره ۱۹۹۰/۱۲/۵ تا ۲۰۱۰/۲/۲ استفاده شده است. این اطلاعات از پایگاه اینترنتی وزارت انرژی ایالات متحده، آژانس اطلاعات انرژی<sup>۱</sup> استخراج شده اند. شکل (۲)، نمودار زمانی لگاریتم قیمت ها را در دوره مورد بررسی نشان می دهد. همان گونه که در ادبیات بازارهای مالی متداول است، بازدهی نفت را می توان از رابطه زیر استخراج کرد:

$$R_t = \frac{(P_t - P_{t-1})}{P_t}, r_t = \ln(1 + R_t) = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (1)$$



شکل ۲- لگاریتم قیمت های نفت خام برنت و وست تگراس اینترمیدیت

بر اساس رابطه‌ی (۱)، سری بازده هر دو نفت را تشکیل داده‌ایم که نمودار آن‌ها را می‌توان در شکل (۳) مشاهده کرد:



شکل ۳- سری‌های بازدهی نفت خام برنت و وست‌تگزاس اینترمیدیت

سپس به تحلیل اکتشافی داده‌ها می‌پردازیم؛ جدول (۱)، نتایج این بررسی را به اختصار نشان می‌دهد. با توجه به آماره‌ی جارک-برا<sup>۱</sup> (۱۹۸۰)، فرضیه‌ی نرمال بودن هر دو سری با اطمینان رد می‌شود.

#### بررسی ماتانی

افزون بر این، می‌توان مانایی سری‌های بازده را با استفاده از آزمون‌های دیکی-فولر گسترش‌یافته<sup>۲</sup> (۱۹۷۹) و فیلیپس-پرون<sup>۳</sup> (۱۹۸۸)، بررسی کرد. مقادیر آماره‌های این دو آزمون در جدول (۲) ارائه شده‌اند. با توجه به نتایج، می‌توان ادعا کرد که هیچ شاهدی مبنی بر وجود ریشه‌ی واحد در هر دو سری دیده نمی‌شود؛ پس می‌توان هر دو سری را

1- Jarque & Bera.

2- Augmented Dickey-Fuller (ADF).

3- Philips & Perron.

مانا دانست. باید متذکر شد که این آماره‌ها با فرض وجود عرض از مبدأ در معادله‌ی آزمون به دست آمده‌اند.

جدول ۱-آماره‌های توصیفی سری‌های بازدهی نفت خام برنت و وست تگزاس اینترمیدیت

	Brent	WTI
<b>Observations</b>	۵۰۰۰	۵۰۰۰
<b>Mean</b>	۰/۰۰۰۳۱۳	۰/۰۰۱۹۰
<b>Median</b>	۰/۰۰۰۵۱۲	۰/۰۰۰۵۰۹
<b>Maximum</b>	۰/۱۸۱۲۹۷	۰/۱۸۸۶۷۷
<b>Minimum</b>	-۰/۳۶۱۲۱۴	-۰/۴۰۶۳۹۶
<b>Standard Deviation</b>	۰/۰۲۴۵۷۰	۰/۰۲۶۰۸۸
<b>Skewness</b>	-۰/۷۴۴۲۲۲	-۰/۹۸۳۶۸۶
<b>Kurtosis</b>	۱۷/۹۵۳۵۶	۱۹/۷۲۳۴۷
<b>Jarque-Bera</b>	۴۷۰۴۶/۷۵	۵۸۹۳۱/۰۵
<b>P-value</b>	۰/۰۰۰۰۰۰	۰/۰۰۰۰۰۰

منبع: نتایج پژوهش

اغلب این مرحله را مرحله‌ی پیش‌پردازش<sup>۱</sup> می‌نامند و تقریباً در تمامی مطالعات اقتصادسنجی، دیده می‌شود، اما شاید این پرسشن وجود داشته باشد که چرا چنین مرحله‌ای در مطالعات مبتنی بر شبکه‌های عصبی نیز ضرورت دارد. به کارگیری داده‌های خام، از یک سو در فرایند یادگیری شبکه مؤثر است؛ به این معنا که دستکاری داده‌ها ممکن است به تغییر ماهیت و روند طبیعی آن‌ها منجر شود و این امر، به نوبه‌ی خود می‌تواند برای فرایند آموزش در شبکه‌های عصبی مشکل‌ساز شود، اما از سوی دیگر برای رسیدن به الگویی که از نظر آماری قابل اعتماد باشد، ناگزیر باید مانایی سری‌ها را تأمین کرد. (کولکارنی و حیدر، ۲۰۰۹). در این مطالعه، سری‌های بازده، مانا بودند و به همین دلیل نیازی به اعمال تبدیل‌های آماری وجود نداشت.

جدول ۲- نتایج آزمون‌های مانابی دیکی فولر و فیلیپس پرون برای سری‌های بازده

	Brent	WTI
ADF	-۶۸/۶۴۸۰۱	-۵۲/۷۴۶۸۶
Philips-Perron	-۶۸/۶۳۳۰۴	-۷۱/۴۱۸۷۴-

منبع: نتایج پژوهش

### برآورد الگوهای اقتصادسنجی بی‌ثباتی

در این بخش، از یک سو برای تأمین ورودی‌های الگوی ترکیبی و از سوی دیگر برای انجام دادن پیش‌بینی‌های مبتنی بر GARCH(1,1)، به برآورد الگوی اقتصادسنجی بی‌ثباتی می‌پردازیم. برای این منظور معادله‌ی میانگین را با توجه به نمودار سری‌های بازده، تنها با عرض از مبدأ تعریف می‌کنیم. به علاوه، از آن جا که الگوی GARCH(1,1) در بسیاری از مقالات این حوزه به عنوان الگویی کارآمد در پیش‌بینی بی‌ثباتی معرفی شده است، به برآورد آن می‌پردازیم. مدل‌سازی و برآوردهای اقتصادسنجی با استفاده از نرم‌افزار EViews5 انجام گرفته‌اند. الگوی GARCH(1,1) در رابطه‌ی (۲) تعریف شده است:

$$\begin{aligned} r_t &= C + \varepsilon_t, & \varepsilon_t &\sim N(0, h_t) \\ h_t &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \end{aligned} \quad (2)$$

برای هر دو سری بازده را بر عرض از مبدأ رگرس کردۀ‌ایم؛ آماره‌ی آزمون وجود اثرات ARCH-LM test (ARCH) با لحاظ ۳ وقفه در پسماند (با توزیع کای-دو)، در جدول (۳) عرضه شده است. همان‌گونه که انتظار می‌رفت، نتایج آزمون بر وجود اثرات ARCH در هر دو سری دلالت دارد. ضرایب مربوط به معادله‌ی بی‌ثباتی نیز در همین جدول ارائه شده‌اند. در این برآوردها، توزیع جمله‌ی اخلال را نرمال (گاووسی) فرض کرده‌ایم.

جدول ۳- برآورد الگوی اقتصادسنجی بی‌ثباتی GARCH(1,1) برای سری‌های بازده

	Brent	WTI
ARCH-LM	۲۰/۳/۲۱۱۹	۱۹۹/۳۲۷۵
Intercept	۴/۶۳۰-۶	۶/۱۷۵-۶
ARCH parameter	۰/۰۶۹۳۲۴	۰/۰۸۸۷۸۹
GARCH parameter	۰/۹۲۵۰۶۰	۰/۹۰۷۲۹۱

منبع: نتایج پژوهش

لازم به یادآوری است که همان‌گونه که دیده می‌شود، مجموع ضرایب ARCH و GARCH برای هر دو سری، از نظر آماری تفاوت معناداری با یک ندارد؛ بنابراین می‌توان نتیجه گرفت که اثر شوک‌ها در قیمت نفت کاملاً ماندگار است. این نتیجه با یافته‌های فونگ و سی (۲۰۰۲)، آنولوچی (۲۰۰۹) و ابریشمی و همکاران (۱۳۸۷) نیز سازگار است.

### معیارهای سنجش قدرت پیش‌بینی

برای سنجش قدرت پیش‌بینی الگوهای مختلف، معیارهای متفاوتی در ادبیات پیش‌بینی تعریف شده است، که در این میان می‌توان به معیارهای زیر اشاره کرد:

$$RMSE = \sqrt{\sum_{T+1}^{T+h} \frac{(\hat{y}_t - y_t)^2}{h}}$$

جذر میانگین مربع خطای پیش‌بینی:

$$MAE = \sum_{T+1}^{T+h} \frac{|\hat{y}_t - y_t|}{h}$$

میانگین قدرمطلق خطای پیش‌بینی:

$$MAPE = \sum_{T+1}^{T+h} \frac{|\hat{y}_t - y_t|}{\frac{y_t}{h}}$$

میانگین قدرمطلق درصد خطای پیش‌بینی:

$$TIC = \frac{\sqrt{\sum_{T+1}^{T+h} (\hat{y}_t - y_t)^2}}{\sqrt{\sum_{T+1}^{T+h} \frac{\hat{y}_t^2}{h}} + \sqrt{\sum_{T+1}^{T+h} \frac{y_t^2}{h}}}$$

ضریب نابرابری تایل:

در این مطالعه از دو معیار نخست استفاده شده است.

### نتایج پیش‌بینی

در این مرحله، نتایج حاصل از پیش‌بینی بی‌ثباتی را برای هر دو سری، محاسبه و در جدول (۴) ارائه شده است. پیش از بررسی و مقایسه نتایج باید اشاره کرد که نرم‌افزار محاسباتی به کار رفته در این مطالعه بر پایه‌ی روش تلفیقی الگوریتم ژنتیک و شبکه‌ی

عصبی GMDH (نریمان زاده و همکاران<sup>۱</sup>، ۲۰۰۳)، با هدف بهینه‌سازی دو منظوره<sup>۲</sup> (امانی فرد و همکاران<sup>۳</sup>، ۲۰۰۸)، کمینه‌ی خطای مدل‌سازی و پیش‌بینی، با استفاده از نرم‌افزار Matlab طراحی شده که مجموعه‌ای از نقاط بهینه (آتشکاری و همکاران<sup>۴</sup>، ۲۰۰۷)، خطای پیش‌بینی و الگوسازی فرایند را گزارش می‌دهد.

برای پیش‌بینی بی‌ثباتی، چهار الگوی مختلف مورد بررسی قرار گرفته‌اند. الگوی نخست، الگوی GARCH(1,1) است که متداول ترین روش برای پیش‌بینی بی‌ثباتی در ادبیات اقتصادسنجی به شمار می‌آید. برآوردهای مربوط به ضرایب این الگو در بخش‌های پیشین مقاله ارائه شد. در ردیف نخست جدول (۴) خطای پیش‌بینی بی‌ثباتی الگوی GARCH(1,1) برای هر دو سری نفت‌خام برنت و وست‌تگزاس بر حسب دو آماره‌ی جذر میانگین مربع خطأ (RMSE) و میانگین قدر مطلق خطای پیش‌بینی (MAE) ارائه شده‌اند، اما در سه الگوی دیگر با استفاده از شبکه‌ی عصبی GMDH، به پیش‌بینی بی‌ثباتی پرداخته‌ایم. شرایط اجرای شبکه در هر سه الگو یکسان بوده است، به این معنا که برای هر بار اجرای شبکه، ۱۰۰ نسل و برای هر نسل، ۳۰۰ نفر جمعیت در نظر گرفته شده است. شبکه‌ی استفاده شده در تمام الگوهای دارای دو لایه‌ی پنهان است. تعداد مشاهدات هر سری ورودی ۵۰۰۰ مشاهده بوده است، که ۲۰۰ مشاهده‌ی پایانی هر سری برای بررسی کیفیت فرآگیری مدل مورد استفاده قرار گرفته‌اند. تفاوت الگوهای مورد بررسی همان‌گونه که در ادامه بیش‌تر توضیح خواهیم داد به ورودی‌های آن‌ها باز می‌گردد.

### الگوی پایه

ردیف دوم جدول (۴)، به بررسی نتایج نخستین الگوی پیش‌بینی مبتنی بر شبکه‌ی عصبی GMDH اختصاص دارد. در این الگو، سه سری مربوط به وقفه‌های اول تا سوم سری بی‌ثباتی (انحراف معیار قیمت) به عنوان ورودی شبکه در نظر گرفته شده‌است. نرم‌افزار محاسباتی پیش‌گفته با در اختیار داشتن این ورودی‌ها، سری بی‌ثباتی را

1- Nariman-zadeh et al.

2- Multi-Objective Optimization Program.

3- Amanifard et al.

4- Atashkari et al.

پیش‌بینی کرده است. نتایج مربوط به خطای پیش‌بینی در دومین ردیف از جدول (۴) ارائه شده‌اند.

### الگوی توسعه‌یافته

همانند الگوی پایه با تکیه بر قدرت شبکه‌ی عصبی به پیش‌بینی بی‌ثباتی پرداخته است. تفاوت الگوی توسعه‌یافته و الگوی پایه به ورودی‌های آن‌ها مربوط می‌شود. در الگوی توسعه‌یافته چهار وقفه‌ی نخست سری بی‌ثباتی و نیز چهار وقفه‌ی نخست سری بازده (برای هر یک از انواع قیمت‌های نفت خام) به عنوان ورودی شبکه در نظر گرفته شده‌اند. انتظار این است که افزودن وقفه‌ی چهارم بی‌ثباتی و نیز لحاظ کردن سری‌های بازده، که احتمالاً اطلاعات تازه‌ای را به شبکه منتقل می‌کنند، به عنوان ورودی به بهبود فرایند یادگیری شبکه و در نتیجه، کاهش خطای پیش‌بینی بیانجامد. باید توجه داشت که پیش‌بینی‌های شبکه‌ی عصبی کاملاً تحت تأثیر ورودی‌ها قرار دارند. این ترکیب از ورودی‌ها پس از سعی و خطای مقایسه‌ی تجربی ترکیب‌های مختلف ورودی‌های شبکه، به عنوان مؤثرترین متغیرها در فرایند یادگیری شبکه برگزیده شده‌اند. ردیف سوم جدول (۴)، خطای پیش‌بینی الگوی توسعه‌یافته را نشان می‌دهد.

جدول ۴- آماره‌های خطای پیش‌بینی بی‌ثباتی در چهار الگوی مورد مطالعه برای سری‌های بازده

	نفت برنت		نفت وست تگزاس	
	RMSE	MAE	RMSE	MAE
الگوی اقتصادستنجی	۰/۰۰۲۴۳۸۷	۰/۰۰۰۶۷۸۲۵۵	۰/۰۰۲۹۰۱۱	۰/۰۰۰۷۷۰۰۹۹
الگوی پایه	۰/۰۰۲۳۶۷۷	۰/۰۰۰۶۷۹۹۰۵	۰/۰۰۲۸۴۷۹	۰/۰۰۰۷۵۰۵۴۱
الگوی توسعه‌یافته	۰/۰۰۲۲۹۹۸	۰/۰۰۰۶۹۰۶۷۷	۰/۰۰۲۸۱۵۳	۰/۰۰۰۷۵۸۱
الگوی ترکیبی	۰/۰۰۲۲۸۲۸	۰/۰۰۰۶۹۳۵۲۶	۰/۰۰۲۸۱۵۴	۰/۰۰۰۷۶۱۳۴

منبع: نتایج پژوهش

### الگوی ترکیبی

در نهایت، ردیف چهارم، نتایج مربوط به الگوی ترکیبی را نمایش می‌دهد. الگوی ترکیبی بر پایه‌ی ترکیب الگوهای توسعه‌یافته و الگوی اقتصادستنجی طراحی شده است.

شبکه‌های عصبی اصولاً در زمرة‌ی روش‌های داده‌کاوی<sup>۱</sup> قرار می‌گیرند. به عبارت بهتر، بدون در نظر گرفتن مبانی نظری و فقط با تقریب بهترین الگوی ممکن برای فرایند GARCH(1,1) تولید داده‌ها، به پیش‌بینی بی‌ثباتی می‌پردازند. الگوی اقتصادسنجی (GARCH(1,1)) خود به عنوان یکی از پرکاربردترین الگوهای پیش‌بینی پذیرفته شده است و بنابراین احتمالاً اطلاعات ارزشمندی درباره‌ی فرایند تولید داده‌ها در اختیار الگوریتم کمینه‌کننده‌ی خطاب قرار خواهد داد. به همین دلیل در الگوی ترکیبی شبکه‌ی عصبی GMDH و GARCH(1,1)، برای هر سری نفت‌خام مقادیر متناظر  $\alpha_{t-1}$  و  $\beta_{t-1}$  به عنوان ورودی‌های شبکه، به هشت ورودی منظور شده در الگوی توسعه‌یافته، شامل چهار وقفه‌ی بی‌ثباتی و چهار وقفه‌ی بازده، افزوده شده‌اند. در الگوی ترکیبی، فرض بر این است که سری حاصل از برآورد الگوی اقتصادسنجی می‌تواند به بهبود فرایند یادگیری شبکه کمک کند. فرضی که البته در مقام تجربه، اگر نگوییم تأیید شده، دست کم رد نیز نشده است.

جدول ۵- رتبه‌بندی الگوهای پیش‌بینی بی‌ثباتی بر حسب معیار جذر میانگین مربع خطای پیش‌بینی

رتبه	نفت برنت	نفت وست تگزاس
۱	الگوی ترکیبی	الگوی توسعه‌یافته
۲	الگوی توسعه‌یافته	الگوی ترکیبی
۳	الگوی پایه	الگوی پایه
۴	الگوی اقتصادسنجی	الگوی اقتصادسنجی

منبع: نتایج پژوهش

جدول (۵)، رتبه‌بندی چهار الگوی مورد مطالعه را به ترتیب کمترین خطای پیش‌بینی بی‌ثباتی بر حسب معیار جذر میانگین مربع خطای پیش‌بینی (RMSE) نشان می‌دهد. ملاحظه می‌شود که برای سری زمانی قیمت نفت برنت، الگوی ترکیبی بهترین عملکرد پیش‌بینی را به خود اختصاص داده است. الگوی توسعه‌یافته در جایگاه دوم و الگوهای پایه و الگوی اقتصادسنجی به ترتیب در رتبه‌های سوم و چهارم قرار می‌گیرند. به طور مشابه برای سری زمانی قیمت نفت وست تگزاس اینترمیت نیز الگوی ترکیبی و

الگوی توسعه‌یافته در دو جایگاه نخست قرار می‌گیرند. گرچه برای این سری الگوی توسعه‌یافته نسبت به الگوی ترکیبی خطای کمتری در پیش‌بینی بی‌ثباتی داشته است، اما اگر به اعداد جدول (۴) مراجعه کنیم، درخواهیم یافت که این برتری بسیار ناچیز است و نمی‌توان به لحاظ آماری آن را معنادار دانست. افزون بر این، بازهم الگوی پایه در رتبه‌ی سوم و الگوی اقتصادسنجی در رتبه‌ی چهارم قرار گرفته‌اند. برتری الگوی ترکیبی و الگوی توسعه‌یافته در پیش‌بینی بی‌ثباتی را می‌توان به کیفیت ورودی‌های آن‌ها نسبت داد، چرا که در الگوی توسعه‌یافته چهار وقفه‌ی بی‌ثباتی و چهار وقفه‌ی بازده را به عنوان ورودی شبکه در نظر گرفتیم و در الگوی ترکیبی دو سری  $\alpha_{1,4,2,1}$  و  $\beta_{1,4,2,1}$  نیز به آن‌ها افزوده شدند. الگوی پایه با توجه به پایین‌تر بودن کیفیت ورودی‌ها، در هر دو سری جایگاه سوم را به خود اختصاص داد. در نهایت، آن‌چه بیش از پیش باید مورد توجه و تأکید قرار گیرد، قدرت شبکه‌ی عصبی GMDH در پیش‌بینی بی‌ثباتی است، چرا که تمامی الگوهای مبتنی بر شبکه در هر دو سری، برتری معناداری نسبت به الگوی متداول اقتصادسنجی GARCH(1,1) از خود نشان داده‌اند.

## ۵- نتیجه‌گیری و پیشنهادات

سری بازدهی قیمت نفت خام، به لحاظ آماری ماناست؛ توزیعی غیرنرمال و میانگینی تقریباً نزدیک به صفر دارد. در این سری، وجود اثرات نوسانات خوش‌های کاملاً مشهود است و برآورد مدل GARCH(1,1)، نشان می‌دهد که اثرات تکانه‌ها در سری بازده کاملاً مانا خواهد بود. در این مطالعه، قدرت پیش‌بینی چهار الگوی مختلف مقایسه شده است که عبارتند از الگوی اقتصادسنجی GARCH(1,1)، شبکه‌ای با ورودی سه وقفه‌ی نخست سری بی‌ثباتی (الگوی پایه)، شبکه‌ای با ورودی چهار وقفه‌ی نخست بی‌ثباتی و چهار وقفه‌ی نخست بازده (الگوی توسعه‌یافته)، و الگویی ترکیبی که در آن دو سری  $\alpha_{1,4,2,1}$  و  $\beta_{1,4,2,1}$  به عنوان ورودی به ورودی‌های الگوی توسعه‌یافته افزوده شده‌اند.

نتایج نشان می‌دهد که برای نفت برنت، بر حسب معیار جذر میانگین مربع خطای پیش‌بینی، شبکه‌های عصبی عملکرد بهتری نسبت به الگوی اقتصادسنجی داشته‌اند؛ کمترین خطای در الگوی ترکیبی دیده می‌شود. پس از آن دو شبکه‌ی عصبی قرار دارند و در نهایت الگوی GARCH(1,1)، از نظر خطای پیش‌بینی در رتبه‌ی چهارم قرار می‌گیرد. در سری نفت خام وست‌تگزاس نیز شرایط مشابهی دیده می‌شود. برای این

سری شبکه‌ی عصبی دوم و شبکه‌ی ترکیبی نتایجی تقریباً مشابه داشته‌اند و البته، شبکه‌ی عصبی دوم با اختلافی ناچیز، پیش‌بینی‌های بهتری ارائه داده است؛ بعلاوه، باز هم تمامی شبکه‌های عصبی در مقایسه با الگوی GARCH(1,1) نتایج بهتری داشته‌اند. این امر نشان می‌دهد که شبکه‌ی عصبی در شبیه‌سازی فرایند داده‌ها از ظرفیت بالایی برخوردار است و می‌تواند عملکردی بهتر از الگوهای اقتصادسنجی در پیش‌بینی بی‌ثباتی داشته باشد.

در پایان باید یادآوری کرد که ادامه‌ی پژوهش در این حوزه دست کم در دو مسیر متمایز امکان‌پذیر است. جدا از این که بررسی آثار اقتصادی تغییرات قیمت یا بی‌ثباتی بازار نفت بر متغیرهای حقیقی اقتصاد، هم‌چنان موضوعی پرکاربرد تلقی می‌شود، از یک سو می‌توان برای همین شبکه در جست‌وجوی ورودی‌هایی بهتر بود؛ فرایند بهبود ورودی‌ها هم‌چنان که در متن مقاله نیز اشاره شد، فرایندی مبتنی بر سعی و خطا و وابسته به تجربه‌ی پژوهش‌گر است. به بیان روش‌تر، همواره این احتمال وجود دارد که بتوان با جایگزینی ورودی‌های مناسب‌تر به نتایج بهتری دست یافت؛ از سوی دیگر طراحی شبکه نیز می‌تواند مبنای به انجام رساندن پژوهش‌های تازه باشد. گرچه الگوریتم GMDH و ساختار شبکه‌ی مورد استفاده در این مطالعه، در پژوهش‌های دیگری نیز به کار گرفته شده است، اما به هر حال مقایسه‌ی نتایج حاصل از پیش‌بینی با شبکه‌های مختلف می‌تواند دست کم شاهدی بر کارآمدی این شبکه باشد.

## فهرست منابع

- ابریشمی، حمید، مهرآرا، محسن، آریانا، یاسمین (۱۳۸۶)، ارزیابی عملکرد مدل‌های پیش‌بینی بی‌ثباتی قیمت نفت؛ مجله‌ی تحقیقات اقتصادی، شماره‌ی ۷۸، صص ۱-۲۱.
- ابریشمی، حمید، مهرآرا، محسن، غنیمی‌فرد، حجت‌الله...، کشاورزیان، مریم (۱۳۸۷)، اثر نوسانات قیمت نفت بر رشد اقتصادی برخی کشورهای OECD به وسیله‌ی تصریح غیرخطی قیمت نفت؛ مجله‌ی دانش و توسعه، شماره‌ی ۲۲، صص ۷-۲۲.
- اصفهانیان، مجید، امین‌ناصری، محمدرضا (۱۳۸۷)، ارائه‌ی یک مدل شبکه‌ی عصبی جهت پیش‌بینی کوتاه‌مدت قیمت نفت‌خام، نشریه‌ی بین‌المللی دانشگاه علم و صنعت ایران، شماره‌ی اول، جلد ۱۹، صص ۳۵-۲۷.

فرجامنیا، ایمان، ناصری، محسن، احمدی، سیدمحمدمهدی(۱۳۸۶)، پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی، فصلنامه‌ی پژوهش‌های اقتصادی ایران، شماره‌ی ۳۲، صص ۱۸۳-۱۶۱.

منهاج، محمد باقر(۱۳۷۹)، مبانی شبکه‌های عصبی مصنوعی، مرکز نشر دانشگاهی امیرکبیر.

Agnolucci, P. (2009) “*Volatility in Crude Oil Futures: A Comparison of The Predictive Ability of GARCH and Implied Volatility Models*”. Energy Economics 31, 316–321.

Amanifard, N. Nariman-Zadeh, M. Borji, A. Khalkhali and A. Habibdoust,(2008), *Modelling and Pareto Optimization of Heat Transfer and Flow Coefficients in Microchannels using GMDH Type Neural Networks and Genetic Algorithms*, Energy Conversion and Management, Vol. 49, Issue 2, February, Pages 311-325.

Atashkari, N. Nariman-Zadeh, M. Gölcü, A. Khalkhali and A. Jamali, (2007) “*Modeling and Multi-Objective Optimization of a Variable Valve-timing Spark-ignition Engine using Polynomial Neural Networks and Evolutionary Algorithms*”, Energy Conversion and Management, Vol. 48, Issue 3, March, Pages 1029-1041.

Bildirici, M., Ersin, Ö. (2009) “*Improving Forecasts of GARCH Family Models with The Artificial Neural Networks: An Application to The Daily Returns in Istanbul Stock Exchange*”. Expert Systems with Applications 36, 7355–7362.

Bollerslev, T., Wooldridge, J.M., (1992) “*Quasi-maximum Likelihood Estimation and Inference in Dynamic Models with Time Varying Covariances*”. Econometric Reviews 11, 143– 172.

Cheong, C. W. (2009) “*Modeling and Forecasting Crude Oil Markets Using ARCH-type Models*”. Energy Policy 37, 2346–2355.

Cologni, A., Manera, M. (2008) “*Oil Prices, Inflation and Interest Rates in A Structural Cointegrated VAR Model for The G-7 Countries*”. Energy Economics 30, 856–888.

Darvizeh, A., Nariman – Zaeleh, N., and Gharababaei, H., (2001), “*GMDH-Type Neural Network Modeling of Explosive Cutting Process of Plate Using Singular value Decomposition*”, ESM'2001, Prague.

Dickey, D., Fuller, W., (1979) “*Distribution of The Estimators for Autoregressive Time Series with A Unit Root*”. Journal of the American Statistical Association 74, 427–431.

Dolenko, S.A., Orlov, Y.V., and Persantev, I.G., (1996), “*Practical Implementation and Use of Group Method of Data Handling (GMDH): Prospects and problems*”, proc. ACEDC' 96, university of Plymouth, Uk.

- Donaldson, R. G., Kamstra, Mark. (1997) "*An Artificial Neural Network-GARCH Model for International Stock Return Volatility*". Journal of Empirical Finance 4, 17-46.
- Farzanegan, M. R. Markwardt, G. (2009) "*The Effects of Oil Price Shocks on The Iranian Economy*". Energy Economics 31, 134–151.
- Ferderer, J.P. (1996) "*Oil Price Volatility and The Macroeconomy*". Journal of Macroeconomics 18 (1), 1-26.
- Fong, W.M., See, K.H., (2002) "*A Markov Switching Model of The Conditional Volatility of Crude Oil Futures Prices*". Energy Economics 24, 71–95.
- Ghaffari, A., Zare, S. (2009) "*A Novel Algorithm for Prediction of Crude Oil Price Variation Based on Soft Computing*". Energy Economics 31, 531–536.
- Hamid, S. A. Iqbal, Z. (2004) "*Using Neural Networks for Forecasting Volatility of S&P 500 Index Futures Prices*". Journal of Business Research 57, 1116– 1125.
- Hamilton, J.D., (1983) "*Oil and The Macroeconomy Since World War II*". Journal of Political Economy 91, 228–248.
- Huang, B. Huang, M. J. Peng, H. (2005) "*The Asymmetry of the Impact of Oil Price Shocks on Economic Activities: An Application of the Multivariate Threshold Model*". Energy Economics 27, 455– 476.
- Ivakhnenko A.G and Ivakhnenko, G.A., (1995), "*The Review of Problems Solvable by Algorithms of the Group Method of Data Handling (GMDH)*", Pattern Recognition and Image Analysis, Vol.5, No.4, pp. 527-535.
- Ivakhnenko, A.G., (1968), "*The Group Method of Data Handling; a Rival of the Method of Stochastic Approximation*", Soviet Automatic Control, 13(3), pp. 43-55.
- Jamali, A., Nariman-zadeh, N., Atashkari, K., (2006), "*Inverse Modelling of Multi-objective Thermodynamically Optimized Turbojet Engines using GMDH and GA*", 14th Annual (International) Mechanical Engineering Conference, Isfahan University of Technology, Isfahan, Iran.
- Jarque, C.M., Bera, A.K., (1980) "*Efficient Tests for Normality, Homoskedasticity and Serial Independence of Regression Residuals*". Economics Letters 6, 225–259.
- Kang, S. H., Kang, S., Yoom, S. (2009) "*Forecasting Volatility of Crude Oil Markets*". Energy Economics 31, 119–125.
- Khashei, M., Bijari, M. (2010) "*An Artificial Neural Network ( $p,d,q$ ) Model for Time Series Forecasting*" Expert Systems With Applications 37, 479-489.
- Kulkarni, S., Haidar, I. (2009) "*Forecasting Model for Crude Oil Price Using Artificial Neural Networks and Commodity Futures Prices*".

International Journal of Computer Science and Information Security (IJCSIS) 2(1), 1-8.

Lardic, S. Mignon,V. (2008) “*Oil Prices and Economic Activity: An Asymmetric Cointegration Approach*”. Energy Economics 30, 847–855.

Lardic, S. Mignon,V. (2006) “*The Impact of Oil Prices on GDP in European Countries: An Empirical Investigation Based on Asymmetric Cointegration*”. Energy Policy 34, 3910–3915.

Lemke, F., (1997), “*Knowledge Extraction from Data Using Self-organizing modeling Technologies*”; ESE. Am. 97, Conferences.

Narayan, P. K. Narayan, S. (2007) “*Modelling Oil Price Volatility*”. Energy Policy 35, 6549–6553.

Nariman-Zadeh, N.; Darvizeh, A.; Ahmad-Zadeh, G. R., (2003), “*Hybrid genetic design of GMDH-type neural networks using singular value decomposition for modeling and prediction of the explosive cutting process*”, Journal of Engineering manufacture Proceedings of the I MECH E Part B, Vol. 217 Pages 779 - 790.

Phillips, P.C.B., Perron, P., (1988) “*Testing for A Unit Root in Time Series Regression*”. Biometrika 75, 335–346.

Poon, S.H., Granger, C.W.J. (2003) “*Forecasting Volatility in Financial Markets: A review*”. Journal of Economic Literature 41, 478–539.

Rafiq, S., Salim, R., Bloch, H. (2009) “*Impact of Crude Oil Price Volatility on Economic Activities: An Empirical Investigation in The Thai Economy*”. Resources Policy 34, 121–132.

Roh, T.H. (2007) “*Forecasting The Volatility of Stock Price Index*”. Expert Systems with Applications 33, 916–922.

Sadorsky, P. (2006) “*Modeling and Forecasting Petroleum Futures Volatility*”. Energy Economics 28, 467–488.

Tseng, C., Cheng Sh., Wang, Y., Peng, J. (2008) “*Artificial Neural Network Model of The Hybrid EGARCH Volatility of The Taiwan Stock Index Option Prices*”. Physica A 387, 3912–3200.

Uri, D.N. (1995) “*Crude Oil Price Volatility and Unemployment in the United States*”. Journal of Energy 21 (1), 29-38.

Uri, D.N. (1996) “*Crude Oil Price Volatility and Agricultural Unemployment in the USA*”. Applied Energy 54 (4), 355-373.

Yu, L., Wang, Sh., Lai, K.K. (2008) “*Forecasting Crude Oil Price with An EMD-based Neural Network Ensemble Learning Paradigm*”. Energy Economics 30, 2623–2635.

Zhang, D. (2008) “*Oil Shock and Economic Growth in Japan: A Nonlinear Approach*”. Energy Economics 30, 2374–2390.