

## کاربرد الگوریتم ژنتیک در بهینه‌سازی معماری شبکه عصبی و پیش‌بینی قیمت نفت (GADDN)

فرزاد فیروزی جهانتیغ<sup>\*۱</sup>

صفورا دهقانی<sup>۲</sup>

تاریخ پذیرش: ۱۳۹۵/۰۸/۱۱

تاریخ دریافت: ۱۳۹۵/۰۲/۰۳

### چکیده

پیش‌بینی صحیح قیمت نفت نقش مهمی را در هدایت سیاست‌های پولی کشورهای مختلف ایفا می‌کند. اهمیت این نقش به‌طور مشهود در کشورهای واردکننده و صادرکننده نفت به چشم می‌خورد. در این مقاله از الگوریتم ژنتیک برای بهینه‌سازی معماری و ساختار شبکه عصبی مصنوعی بهره‌برده‌ایم. در طی فرآیند بهینه‌سازی، وزن‌ها، بایاس و ساختار شبکه عصبی محاسبه می‌شوند تا بدین طریق از پیچیدگی‌های ناشی استفاده از شبکه عصبی مصنوعی در پیش‌بینی کاسته گردد. برای بررسی عملکرد مدل شبکه عصبی اصلاح‌شده با الگوریتم ژنتیک (GADNN) از آن برای پیش‌بینی قیمت نفت اینترمدیت وست تگزاس (WTI) در سال ۲۰۱۲ تا انتهای ۲۰۱۵ استفاده می‌شود. نتایج پژوهش نشان‌دهنده عملکرد بهتر و دقت بیشتر مدل پیشنهادی پژوهش حاضر در مقایسه با سایر مدل‌های شبکه عصبی مصنوعی در پیش‌بینی قیمت نفت می‌باشد.

**کلیدواژه‌ها:** پیش‌بینی قیمت نفت، شبکه عصبی مصنوعی، الگوریتم ژنتیک.

طبقه‌بندی JEL: C32, C41, C45, C53.

**Email:** firouzi@eng.usb.ac.ir

۱. استادیار گروه مهندسی صنایع دانشگاه سیستان و بلوچستان (\*نویسنده مسئول)

**Email:** s.dehghani@pgs.usb.ac.ir

۲. دانشجوی کارشناسی ارشد مهندسی صنایع دانشگاه سیستان و بلوچستان

## ۱. مقدمه

رشد و توسعه اقتصادی بسیاری از کشورهای جهان وابسته به قیمت نفت است، به همین جهت قیمت نفت، با پیشرفت اقتصادی کشورهای واردکننده و صادرکننده نفت رابطه اساسی داشته و نقش تعیین‌کننده‌ای در رکود و رونق اقتصاد بین‌الملل دارد. آگاهی از تغییرات قیمت نفت برای بسیاری از کشورها امر مهمی تلقی می‌گردد. برای مثال، دولت با آگاهی از قیمت نفت برای نحوه استخراج منابع طبیعی نفتی برنامه‌ریزی نموده و بانک مرکزی نیز می‌تواند سیاست‌های کارآمدی را در زمان به وجود آمدن بحران‌های نفتی اتخاذ کند (وانگ<sup>۱</sup> و همکاران، ۲۰۱۵: ۵۹۹).

بازار نفت، یکی از بازارهای پرتلاطم انرژی است که پیش‌بینی صحیح آینده آن می‌تواند در تصمیم‌گیری‌های اقتصادی تأثیر مثبت بر جای گذارد. پیش‌بینی یکی از حوزه‌های مهم پشتیبانی تصمیم بوده و در حوزه مسائل مالی و اقتصادی اهمیت ویژه‌ای دارد. وقوع ناگهانی بحران‌های نفتی که در بازار نفت حادث می‌شود، درجه اطمینان بسیاری از پیش‌بینی‌ها را با تردید مواجه می‌سازد؛ اما با آگاهی از قیمت نفت و پیش‌بینی صحیح آن می‌توان فرآیند تصمیم‌گیری خریدوفروش نفت در بازارهای جهانی را تسهیل و بهترین زمان اجرای معاملات و سرمایه‌گذاری‌ها را تعیین نمود. لزوم آگاهی دولت‌ها از تغییرات قیمت این کالای اقتصادی با ارزش، پژوهشگران را به سمت ارائه مدل‌های دقیق‌تر برای پیش‌بینی سوق داده است. بدین منظور محققان جهت پیش‌بینی از روش‌های مختلفی که نشان‌دهنده رفتارهای خطی و غیرخطی قیمت نفت می‌باشند، استفاده نموده‌اند. استفاده از روش‌های مختلف، با ویژگی‌ها و محدودیت‌های خاص، نتایج متفاوتی را در پیش‌بینی به همراه خواهد داشت. با توجه به مکانیسم پیچیده حاکم بر قیمت نفت خام و مقایسه روش‌های خطی و غیرخطی موجود در مرور ادبیات، می‌توان به این نتیجه رسید که مدل‌های خطی کارایی مناسبی در پیش‌بینی روند تغییرات قیمت نفت ندارند. همین امر سبب شده پژوهشگران در سال‌های اخیر از ابزارهای غیرخطی مانند شبکه عصبی مصنوعی جهت پیش‌بینی استفاده نمایند.

تعیین معماری بهینه شبکه‌های عصبی مصنوعی (اعم از تعداد ورودی‌ها، تعداد لایه‌های مخفی، تعداد نورون در هر لایه مخفی و تابع انتقال هر یک از لایه‌ها) در افزایش دقت پیش‌بینی توسط شبکه نقش تعیین‌کننده‌ای دارد و غالباً بر اساس فرآیند آزمون و خطا تعیین می‌شود. با توجه آنچه که بیان شد هدف ما در این تحقیق استفاده از مدلی در پیش‌بینی رفتار غیرخطی قیمت نفت، می‌باشد که علاوه بر عملکرد بهینه از پیچیدگی‌های ناشی از طراحی شبکه عصبی مصنوعی در پیش‌بینی نیز بکاهد. بدین منظور از نتایج تحقیقات جدی<sup>۲</sup> و همکاران (۲۰۱۵) بهره برده و با استفاده از روش شبکه عصبی اصلاح‌شده با الگوریتم ژنتیک (GADNN)<sup>۳</sup> به پیش‌بینی قیمت نفت می‌پردازیم. در مدل این پژوهش

1. Wang

2. Jaddi

3. Genetic Algorithm based Dynamic Neural Network

ابتدا از الگوریتم ژنتیک برای تعیین، ساختار شبکه (تعداد لایه‌ها) و وزن‌های شبکه عصبی و کاهش خطای مراحل آموزش و آزمایش شبکه به صورت هم‌زمان استفاده می‌شود. استفاده از الگوریتم ژنتیک پیچیدگی ناشی از انتخاب شبکه عصبی با ساختار بهینه در پیش‌بینی را کاهش می‌دهد. سپس در مرحله بعد با استفاده از مدل بهینه به دست آمده به پیش‌بینی قیمت نفت پرداخته می‌شود. برای بررسی دقت عملکرد پیش‌بینی مدل پیشنهادی، بدون استفاده از الگوریتم ژنتیک و با استفاده از ساختارهای مختلف شبکه عصبی چندلایه پرسپترون نیز به پیش‌بینی قیمت می‌پردازیم و در نهایت با مقایسه معیارهای عملکردی نظیر میانگین مربعات خطا ( $MSE^1$ ) و ضریب عملکرد حاصل از نتایج پیش‌بینی قیمت نفت با استفاده از شبکه عصبی اصلاح شده با الگوریتم ژنتیک و شبکه عصبی چندلایه پرسپترون بهترین مدل در پیش‌بینی قیمت نفت را تعیین می‌نماییم.

در بخش دوم این پژوهش به مرور ادبیات روش‌های مختلف در پیش‌بینی قیمت نفت می‌پردازیم، در بخش سوم به بیان مبانی نظری شبکه‌های عصبی مصنوعی و شبکه عصبی اصلاح شده با الگوریتم ژنتیک پرداخته می‌شود. در بخش چهارم به تعیین داده‌ها و در بخش پنجم به مدل‌سازی مسئله با دو روش عنوان شده می‌پردازیم و در نهایت با مقایسه معیارهای عملکردی حاصل از نتایج پیش‌بینی توسط هر دو روش، بهترین مدل را در پیش‌بینی قیمت نفت تعیین می‌نماییم.

## ۲. مرور ادبیات

برای پیش‌بینی قیمت نفت از روش‌ها و رویکردهای مختلفی استفاده می‌شود که دقت و نتایج مختلفی را در پیش‌بینی به همراه خواهند داشت. برخی از پژوهشگران از روش‌های سری‌های زمانی و روش‌های مختلف اقتصادسنجی نظیر  $GARCH^2$ ، مدل‌های  $ARMAX^3$ ، مدل  $ARMA^4$  و ... جهت پیش‌بینی قیمت نفت استفاده نموده‌اند. از میان آن‌ها می‌توان به مورانا<sup>۵</sup> (۲۰۰۱)، أبرامسون<sup>۶</sup> و همکاران (۲۰۰۳) اشاره کرد. این پژوهشگران برای نشان دادن دقت نتایج مدل خود به مقایسه نتایج به دست آمده از پژوهش‌شان با سایر مدل‌ها در پیش‌بینی پرداخته‌اند. کمیجانی و همکاران (۱۳۹۲) نیز به مقایسه‌ی انواع مدل‌های واریانس ناهمسان شرطی در مدل‌سازی و پیش‌بینی نوسانات قیمت نفت پرداختند. اشاره به این نکته ضروری است که مدل‌های اقتصادسنجی قیمت نفت خام را با توجه به مدل‌های خطی یا نزدیک به خطی پیش‌بینی می‌کنند؛ اما در حقیقت قیمت نفت خام باید به عنوان یک متغیر پیچیده و پر نوسان برای پیش‌بینی در نظر گرفته شود. با این توضیحات می‌توان به مطالعات عباسی‌نژاد و همکاران

1. Mean Standard Error

2. Generalized Autoregressive Conditional Heteroskedastic

3. AutoRegressive Moving Average with Exogenous Variables (ARMAX) Model.

4. Auto-Regressive Moving Average

5. Morana

6. Abramson

(۱۳۹۲) اشاره کرد که به تحلیل و پیش‌بینی اثرات غیرخطی در بازار نفت پرداختند. از این رو، محققانی نظیر جوانمرد و فقیدیان (۱۳۹۳) مدل پیش‌بینی خاکستری که هسته نظریه سیستم‌های خاکستری می‌باشد را مدلی مناسب برای پیش‌بینی قیمت نفت معرفی نموده‌اند. نتایج حاصل از اجرای مدل پیشنهادی آنها نشان می‌دهد با استفاده از مدل پیش‌بینی خاکستری می‌توان عملکرد پیش‌بینی قیمت نفت را به صورت چشم‌گیری بهبود بخشید و نتایجی با خطای کمتر و دقت بیشتر به دست آورد. همچنین، برخی دیگر از محققان به ترکیب روش‌های مختلف جهت پیش‌بینی پرداخته و دقت مدل ترکیبی مورد استفاده‌شان را با نتایج سایر مدل‌ها مقایسه نموده‌اند. نظیر ابریشمی و همکاران (۱۳۹۲) که برای پیش‌بینی سری زمانی نفت خام ترکیبی از تبدیل موجک، مدل‌های ARMAX، رگرسیون هارمونیک و مدل هلت-وینترز را استفاده نمودند و با مقایسه مدل پیشنهادی با مدل ARMA، نشان دادند که مدل پیشنهادی پیش‌بینی صحیح‌تر با خطای کمتری را برای قیمت نفت خام ارائه می‌دهد.

شبکه‌های عصبی مصنوعی از جمله ابزارهای غیرخطی با توانایی تعمیم ساختار آموزش دیده برای پیش‌بینی رفتار قیمت نفت در آینده می‌باشند. مقالات متعددی وجود دارد که دال بر مفید بودن مدل شبکه‌های عصبی برای پیش‌بینی متغیرهای اقتصادی است، از بین این مقالات می‌توان به مطالعات: حیدر<sup>۱</sup> و همکاران (۲۰۰۸)، پن<sup>۲</sup> و همکاران (۲۰۰۹) و لیکس<sup>۳</sup> و همکاران (۲۰۰۹) اشاره کرد که با استفاده از روش‌های مختلف شبکه عصبی مصنوعی به پیش‌بینی قیمت نفت پرداختند. صادقی و همکاران (۱۳۹۰) نیز از شبکه عصبی مصنوعی برای پیش‌بینی روزانه سبد نفت خام ایک بهره جستند. وو و شهیدپور<sup>۴</sup> (۲۰۱۰) عملکرد شبکه عصبی در پیش‌بینی را، با بررسی معیارهای ریشه میانگین مربعات خطا (RMSE)<sup>۵</sup> و Dstate<sup>۶</sup> بهبود بخشیدند. در همین زمینه موقرنژاد<sup>۷</sup> و همکاران (۲۰۱۱) قیمت نفت را با استفاده از شبکه عصبی مصنوعی و با ثابت در نظر گرفتن متغیر زمان پیش‌بینی کردند، بدین ترتیب ماهیت پویای روند پیش‌بینی در نظر گرفته نشد. پس از آن جمازی و اولویی<sup>۸</sup> (۲۰۱۲) به منظور در نظر گرفتن وابستگی متغیر زمان از شبکه عصبی پویا چندلایه با استفاده از روش HARR & TOUR و تجزیه موجک و الگوریتم آموزش BP<sup>۹</sup> برای آموزش شبکه عصبی، مدل ترکیبی را برای پیش‌بینی قیمت نفت گسترش دادند. تحقیقات عنوان شده در جدول ۱ به مرور ادبیات تحقیقاتی می‌پردازد که برخی از محققان با استفاده از شبکه عصبی و روش‌های مختلف به پیش‌بینی قیمت نفت پرداخته و با مقایسه معیارهای عملکردی، عملکرد بهتر شبکه عصبی را نسبت به سایر مدل‌های پیش‌بینی نشان داده‌اند.

1. Haidar
2. Pan
3. Lackes
4. Wu and Shahidpour
5. Root Mean Standard Error
6. Direction statistics (Dstat)
7. Movagharnjad
8. Jammazi and Aloui
9. Back Propagation

جدول ۱: مقایسه روش‌های مختلف پیش‌بینی قیمت نفت

نویسندگان	سال	روش‌های مورد مقایسه با شبکه عصبی
مصطفی و المرسی <sup>۱</sup>	۲۰۱۶	شبکه عصبی مصنوعی RBF و MLP و برنامه‌نویسی بر اساس ژن (GEP <sup>۲</sup> ) و روش ARIMA
عباسی‌گودرزی <sup>۳</sup> و همکاران	۲۰۱۴	سری‌های زمانی و شبکه‌های عصبی مصنوعی پویا
آزاده <sup>۴</sup> و همکاران	۲۰۱۲	رگرسیون فازی
علیزاده و مافی‌نژاده <sup>۵</sup>	۲۰۱۰	شبکه عصبی رگرسیون تمپیم‌یافته
یوسفی و همکاران	۱۳۹۲	مدل ARMAX و پیش‌بینی تقاضای نفت خام ایران
گلستانی و گرگینی	۱۳۹۱	مدل‌های VAR <sup>۶</sup> ، ARIMA <sup>۷</sup> و پیش‌بینی تقاضای جهانی نفت
دشتی‌رحمت‌آبادی و همکاران	۱۳۹۰	ARMA و پیش‌بینی قیمت نفت خام ایران
پور کاظمی و اسدی	۱۳۸۸	ARIMA
الکساندریس و لوانیز <sup>۸</sup>	۲۰۰۸	از ترکیب شبکه‌های عصبی و تبدیل موجک
مشیری و فروتن	۱۳۸۳	GARCH, ARMA
مهرگان و سلمانی	۱۳۹۳	مدل EGARCH و مدل‌های چرخشی مارکف

با توجه به نتایج عنوان شده در جدول ۱، مقایسه نتایج حاصل از روش‌های خطی یا نزدیک به خطی مطلوبیت استفاده از شبکه‌های عصبی مصنوعی را نسبت به سایر مدل‌ها نشان داده است. در رویکرد پیشنهادی در این مقاله به مقایسه نتایج حاصل از شبکه‌های عصبی مختلف که همگی آن‌ها ماهیت غیرخطی دارند در پیش‌بینی قیمت نفت استفاده شده است تا مقایسه نتایج به واقعیت روند تغییرات قیمت نفت نزدیک‌تر شوند.

تعیین پارامترهایی نظیر انتخاب وزن‌های مناسب، تعداد لایه‌ها و گره‌ها در هر لایه از مشکلات اصلی طراحی بهینه شبکه عصبی می‌باشد. تحقیقات زیادی در جهت کم کردن پیچیدگی شبکه عصبی و توسعه روش‌های مختلف برای آموزش شبکه عصبی صورت گرفته است. سکستون و همکاران<sup>۹</sup> (۱۹۹۸) از الگوریتم تابو سرچ<sup>۱۰</sup> و سکستون و همکاران (۱۹۹۹)، از الگوریتم شبیه‌سازی تبرید و الگوریتم ژنتیک، چالوپ و مایر<sup>۱۱</sup> (۱۹۹۸) از الگوریتم بالارونده هیل<sup>۱۲</sup>، جدی<sup>۱۳</sup> و همکاران (۲۰۱۳)، از

1. Mostafa & El-Masry
2. Gene Expression Programming
3. Abbasi-Godarzi
4. Azade
5. Alizadeh & Mafinezhad
6. Vector Auto Regressive
7. Auto-Regressive Integrated Moving Average
8. Alexandridis and Livanis.
9. Sexton
10. tabu search
11. Chalup & Maire
12. hill climbing
13. Jaddi

ترکیب دو روش تاگوچی و ژنتیک، برای آموزش داده‌ها در شبکه عصبی استفاده کردند. همان‌طور که بیان شد الگوریتم‌های ذکر شده به تعیین وزن‌ها که از مهم‌ترین مراحل آموزش شبکه است می‌پردازند. محققان بسیاری نیز در پژوهش‌های خود با استفاده از الگوریتم ژنتیک به بهینه‌سازی وزن‌های شبکه عصبی پرداختند که از بین آنها می‌توان به پژوهش‌های یونگ و هان<sup>۱</sup> (۲۰۰۳) که به بهیابایی فعالیت‌ها بر مبنای هزینه، لی و هیانچول<sup>۲</sup> (۲۰۱۱) که به طراحی سیستم‌های اینترنتی جهت تجارت الکترونیک و مخاطب رفیعی<sup>۳</sup> و همکاران (۲۰۱۱) که به پیش‌بینی بهبود مالی شرکت‌ها پرداختند، اشاره کرد. منجمی و همکاران (۱۳۸۸) پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک و مقایسه‌ی آن با شبکه عصبی مصنوعی پرداختند و اصفهانیان و امین ناصری (۱۳۸۵)، نیز از الگوریتم ژنتیک برای تعیین وزن‌های بهینه شبکه عصبی در پیش‌بینی قیمت نفت خام استفاده نموده و دقت عملکرد شبکه عصبی را در پیش‌بینی افزایش داده‌اند. امین ناصری و قراچه<sup>۴</sup> (۲۰۰۷) و چیروما<sup>۵</sup> و همکاران (۲۰۱۵) نیز با استفاده از الگوریتم ژنتیک به بهینه‌سازی معماری شبکه عصبی (GA-NN<sup>۶</sup>) برای پیش‌بینی قیمت نفت پرداختند و از این طریق عملکرد شبکه عصبی در پیش‌بینی را با تعیین پارامترهای بهینه افزایش دادند.

در سال‌های اخیر محققان برای بالا بردن عملکرد شبکه عصبی مصنوعی به ترکیب شبکه‌های عصبی با سایر الگوریتم‌ها علاقه‌مند شده‌اند (تی‌سانگ<sup>۷</sup> و همکاران، ۲۰۰۶؛ اوه<sup>۸</sup> و همکاران، ۲۰۰۵؛ اوه و همکاران، ۲۰۰۹). لودرمیر<sup>۹</sup> و همکاران (۲۰۰۶) از ترکیب الگوریتم شبیه‌سازی تبرید و تابو سرچ برای بهینه‌سازی وزن‌ها و نحوه اتصالات در شبکه عصبی استفاده کردند و پس از آن‌ها زانچتین<sup>۱۰</sup> (۲۰۱۱) با ترکیب چندگانه الگوریتم‌های، تابو سرچ، شبیه‌سازی تبرید و ژنتیک تحقیقات لودرمیر و همکاران را گسترش دادند. جدی و همکاران (۲۰۱۵) برای کاهش پیچیدگی شبکه عصبی و ساختار بهینه آن به‌طور هم‌زمان از الگوریتم ژنتیک استفاده نموده‌اند و ساختار GADNN را معرفی نمودند. گانو و بنچیک<sup>۱۱</sup> (۲۰۱۶)، نیز با استفاده از الگوریتم کلونی مورچگان به تعیین معماری شبکه عصبی پرداخته و معماری بهینه را با استفاده از این الگوریتم تعیین کردند.

1. Kyoung & Han
2. Lee & Hyunchul.
3. Mokhatab Rafiei
4. Amin-Naseri & Gharacheh
5. Chiroma
6. Genetic Algorithm-Neural Network
7. Tsong
8. Oh
9. Ludermir
10. Zanchettin
11. Ghanou Bencheikh

در نهایت، ضمن بررسی پژوهش‌های انجام‌شده، مشخص شد که تاکنون از الگوریتم ژنتیک تنها برای تعیین وزن‌های بهینه شبکه عصبی برای پیش‌بینی قیمت نفت خام استفاده شده است؛ اما از الگوریتم ژنتیک برای پیدا کردن مقادیر بهینه وزن‌ها، تعداد لایه‌های پنهان، تعداد گره‌های شبکه عصبی به‌طور هم‌زمان استفاده نشده است. علاوه بر آن تابع برازندگی که به‌طور هم‌زمان خطا و معماری شبکه عصبی را در پیش‌بینی قیمت نفت خام محاسبه نموده و بهترین معماری را در خروجی نمایش دهد تعیین کند، مورد استفاده قرار نگرفته است؛ بنابراین، در این مقاله با استفاده از روش تصحیح‌شده شبکه عصبی با الگوریتم ژنتیک (GADNN) به پیش‌بینی قیمت نفت خام می‌پردازیم و برای بررسی دقت عملکرد پیش‌بینی، داده‌های قیمت نفت WTI<sup>۱</sup> را با استفاده از مدل شبکه عصبی مصنوعی پرسپترون چندلایه MLP<sup>۲</sup>، نیز پیش‌بینی خواهیم کرد؛ و در نهایت نتایج حاصل از پیش‌بینی این دو مدل را با استفاده از معیارهای عملکردی مانند R<sup>2</sup> مقایسه کرده و مدل بهینه در پیش‌بینی قیمت نفت انتخاب خواهد شد.

### ۳. مبانی نظری تحقیق

#### ۳-۱. شبکه عصبی مصنوعی و شبکه عصبی پویا

شبکه‌های عصبی مصنوعی، از واحدهای کوچکی به نام نرون تشکیل شده‌اند که شدت اتصالات بین آن‌ها از طریق وزن‌های سیناپسی مشخص می‌شود. هر نرون می‌تواند، ارزش خروجی  $z_l$  را بر اساس جمع وزنی ورودی‌های  $x_j$  بر اساس معادله ۱ محاسبه کند (دریفیوس<sup>۳</sup>، ۲۰۰۵؛ نورگاد<sup>۴</sup> و همکاران، ۲۰۰۰) (شکل ۱).

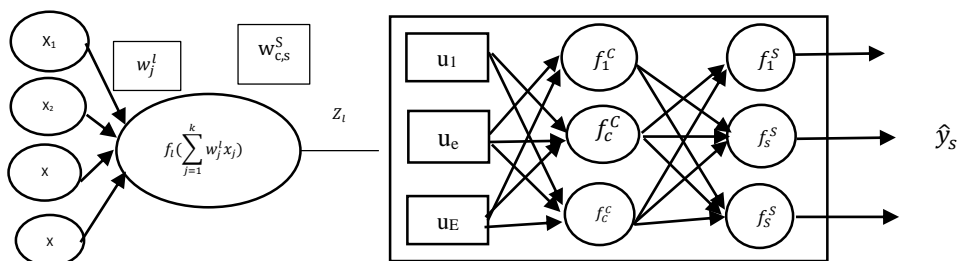
$$z_l = f_l \left( \sum_{j=1}^k w_{lj}' x_j \right) \quad (1)$$

که در آن  $w_j$  جمع ضرایب وزن‌های سیناپسی، اندیس  $l$  نشان‌دهنده تعداد نرون‌ها و  $f_l$  تابع فعال‌سازی شبکه عصبی می‌باشد. به‌طور کلی پارامترهای مختلف شبکه عصبی بر اساس جدول ۲ عبارت‌اند از:

1. West Texas Intermediate
2. Multi-Layer Perceptron
3. Dreyfus
4. Norgaard

جدول ۲: پارامترهای مختلف شبکه عصبی مصنوعی

متغیرها	تعریف	متغیرها	تعریف	متغیرها	تعریف
x	داده‌های ورودی	out	خروجی	l	تعداد نرونها
w	وزن‌های سیناپسی	In	ورودی	MSE	میانگین مربعات خطا
y	مقادیر خروجی واقعی	^	مقدار تخمین زده شده	RMSE	ریشه میانگین مربعات خطا
$\hat{y}$	خروجی شبکه عصبی	AF	تابع فعال‌سازی	N	تعداد داده‌های آموزش



شکل ۱: ساختار شبکه عصبی چندلایه پرسپترون

سمت راست یک شبکه عصبی با یک لایه پنهان و سمت چپ نحوه عملکرد یک نرون می‌باشد (نورگاد و همکاران، ۲۰۰۰)

یک خانواده ساده از شبکه‌های عصبی، مدل پرسپترون<sup>۱</sup> می‌باشد. این نوع شبکه‌ها، از یک لایه ورودی (E) جهت اعمال ورودی‌های مسئله یک یا چندلایه پنهان (C) و (S) لایه خروجی که نهایتاً پاسخ‌های مسئله را ارائه می‌نمایند، تشکیل شده‌اند؛ که ساختار آن‌ها در شکل ۲ نمایش داده شده است؛ و ارزش خروجی S در آن‌ها بر اساس معادله ۲ محاسبه می‌گردد:

$$\hat{y}_s = f_s^S \left( \sum_{c=1}^C w_{c,s}^S f_c^C \left( \sum_{e=1}^E w_{e,c}^C u_e \right) \right) \quad (2)$$

که در آن،  $\hat{y}_s$  خروجی شبکه عصبی،  $f_s^S$  تابع فعال‌سازی لایه خروجی،  $w_{c,s}^S$  وزن‌های سیناپسی لایه پنهان و خروجی،  $f_c^C$  تابع فعال‌سازی لایه پنهان،  $w_{e,c}^C$  وزن‌های سیناپسی لایه ورودی و پنهان و  $u_e$  ورودی‌های مختلف شبکه عصبی می‌باشند. مدل‌سازی یک سیستم با استفاده از شبکه عصبی یعنی تعریف معماری مناسب شبکه و تعریف وزن‌های مختلف بهینه. در مدل‌سازی شبکه‌ها، هر الگوی ورودی حاوی اطلاعات مهمی در مورد ساختار داده‌ها می‌باشد. همچنین با استفاده از تابع فعال‌سازی، ارتباط بین ورودی و خروجی در یک شبکه را مشخص می‌گردد. توابع تبدیل به کار گرفته شده توسط محققان در پیش‌بینی اغلب سیگموئید (لجستیک)، تانژانت هایپربولیک و خطی بوده‌اند. گره‌های مخفی در لایه‌های



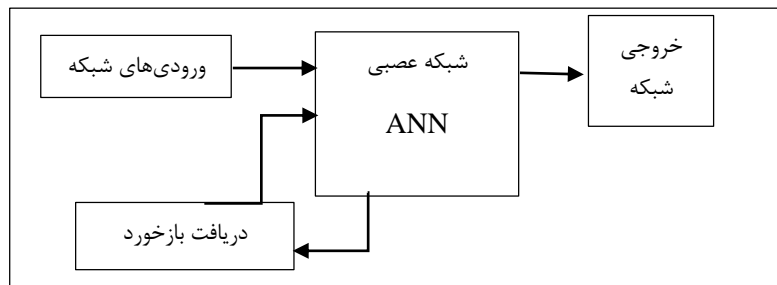
مخفی نیز نگاهت‌های غیرخطی پیچیده را بین متغیرهای ورودی و خروجی برقرار می‌نمایند (بروشکی و همکاران، ۲۰۰۳: ۱۱۰).

در یک شبکه عصبی مجموعه داده‌های ورودی به دو بخش مجزای آموزش و آزمایش تقسیم‌بندی می‌شوند. یادگیری یا آموزش شبکه عصبی عبارت‌اند از روند تعیین مجموعه‌ای از وزن‌ها، به طوری که عملکرد شبکه طراحی شده تقریبی از عملکرد واقعی سیستم بوده و فاصله مقادیر پیش‌بینی شده از مقادیر واقعی حداقل گردد. چون هدف شبکه عصبی، حداقل کردن خطای پیش‌بینی، با استفاده از معیارهایی نظیر MSE یا RMSE، می‌باشد؛ که بر اساس معادله ۳ و ۴ قابل محاسبه می‌باشند:

$$MSE = \frac{\sum (\hat{y}_i - y_i)^2}{n} \quad (۳)$$

$$RMSE = \sqrt{\frac{\sum (\hat{y}_i - y_i)^2}{n}} \quad (۴)$$

که  $y_t$  و  $\hat{y}_t$  به ترتیب روند تغییرات واقعی و روند پیش‌بینی شده می‌باشند. شبکه‌های عصبی به دودسته شبکه‌های ایستا و پویا تقسیم‌بندی می‌شوند. شبکه‌های ایستا مانند شبکه عصبی مصنوعی (ANN) بازخوردی را از عملکرد شبکه دریافت نکرده و در نتیجه تأخیر در روند پیش‌بینی را در نظر نمی‌گیرند؛ اما در شبکه‌های عصبی پویا، تعیین بهترین ساختار شبکه در طول زمان و دریافت بازخورد از شبکه تعیین می‌گردد که ساختار کلی آن‌ها در شکل ۲ نشان داده شده است.



شکل ۲: ساختار شبکه عصبی پویا

شبکه‌های عصبی پویا دارای یک بخش خطی و یک بخش غیرخطی می‌باشند. فرم کلی مدل‌های شبکه عصبی با استفاده از معادله ۵ محاسبه شده و به شرح زیر است (گجراتی و مادسن<sup>۱</sup>، ۱۹۹۸: ۲۱۰):

$$\hat{y}_t = f(u(t), u(t-1), \dots, u(t-n_u), y(t), y(t-1), \dots, y(t-n_y)) \quad (۵)$$

1. Boroushaki  
2. Gujarati and Madsen

که در آن  $f$  یک نگاشت در نظر گرفته شده، به وسیله شبکه عصبی می‌باشد. ورودی‌های شبکه عصبی شامل دو بخش وقفه‌های ورودی (سیگنال‌های ورودی)  $u(t)$  و وقفه‌های مقادیر هدف، (وقفه‌های سیگنال‌های خروجی)،  $y(t)$  می‌باشند. اعداد  $n_u$  و  $n_y$  به ترتیب وقفه‌های ورودی و مقادیر واقعی هدف بوده که با دریافت بازخورد از شبکه عصبی تعیین می‌شوند. برای اینکه شبکه توانایی تعمیم روابط آموخته شده در مدل را داشته باشد، باید از الگوریتم‌های مناسب آموزشی استفاده نمود. از بین الگوریتم‌های مورد استفاده در مدل‌های مختلف شبکه عصبی، در این مقاله برای آموزش داده‌ها الگوریتم لوبنبرگ-مارکوارت<sup>۱</sup> (LM) که دارای سرعتی مناسب می‌باشد و سریع‌تر از بقیه الگوریتم‌ها به همگرایی می‌رسد، استفاده می‌شود. پیش‌پردازش داده یا نرمال‌سازی داده‌ها باعث می‌شود داده‌های مورد استفاده در آموزش شبکه، در دامنه‌ای خاص، فشرده و هماهنگ شوند. با نرمال‌سازی داده‌ها آموزش داده‌ها سریع‌تر و آسان‌تر صورت خواهد گرفت. در نتیجه تمامی ورودی‌ها و خروجی‌های شبکه در فاصله  $[-1, 1]$  و  $[-10, 10]$  با استفاده معادلات ۶ و ۷ نرمال می‌گردند:

$$x_n = \frac{(x - x_0)}{(x_0 - x_{\min})} \times a \quad (۶)$$

$$x_0 = \frac{x_{\min} + x_{\max}}{2} \quad (۷)$$

$X_n$  مقدار نرمال شده ورودی  $x$  و  $x_{\min}$  نشان‌دهنده کوچک‌ترین داده و  $x_{\max}$  نشان‌دهنده بزرگ‌ترین داده در بین مقادیر ورودی،  $a$  یک عدد باینری در بین اعداد ۱ تا ۱۰ و  $x_0$  میانگین ماکزیمم و مینیمم مقادیر، بین داده‌های ورودی می‌باشد.

### ۳-۲. مدل شبکه عصبی پویا اصلاح شده بر اساس الگوریتم ژنتیک GADNN

در مدل‌سازی به وسیله شبکه‌های عصبی پویا، شبکه‌ها می‌توانند دقت دلخواه برای تعیین معماری بهینه شبکه را با دریافت بازخورد از شبکه و فرآیند آزمون و خطا و صرف زمان به دست آورند، اما این امر سبب تعیین بیش از حد لایه‌های پنهان و افزایش پیچیدگی معماری شبکه عصبی می‌گردد. الگوریتم ژنتیک را می‌توان به عنوان یک روش جهت پیدا کردن مقادیر بهینه پارامترهای مختلف شبکه عصبی استفاده نمود. این الگوریتم جستجو را با یک مجموعه ابتدایی از جواب‌های تصادفی که جمعیت اولیه نام‌گذاری می‌شود، آغاز می‌کند و می‌تواند به جستجوی چندجانبه و کاربر روی جمعیتی از متغیرها در آن واحد بپردازد که سبب افزایش احتمال یافتن نقطه بهینه کلی می‌گردد (هپات و هپات<sup>۲</sup>، ۱۹۹۶). بدین ترتیب با استفاده از این الگوریتم می‌توان به طور هم‌زمان ساختار و وزن‌های بهینه شبکه را با استفاده از تابع که معیارهای تعیین کیفیت عملکرد بهینه جواب تولید شده می‌باشند برازندگی تعیین نمود. تابع برازندگی جواب‌های

1. Levenberg- Marquardt Algorithm  
2. Haupt and Haupt

مختلف  $f(s)$ ، بر اساس میانگین خطا  $\varepsilon$  و درصد مجموع وزن‌ها (اتصالات) در شبکه می‌باشد و بر اساس معادله ۸ و ۹ محاسبه می‌گردد:

$$f(s) = \frac{1}{2}(\varepsilon + p) \quad (۸)$$

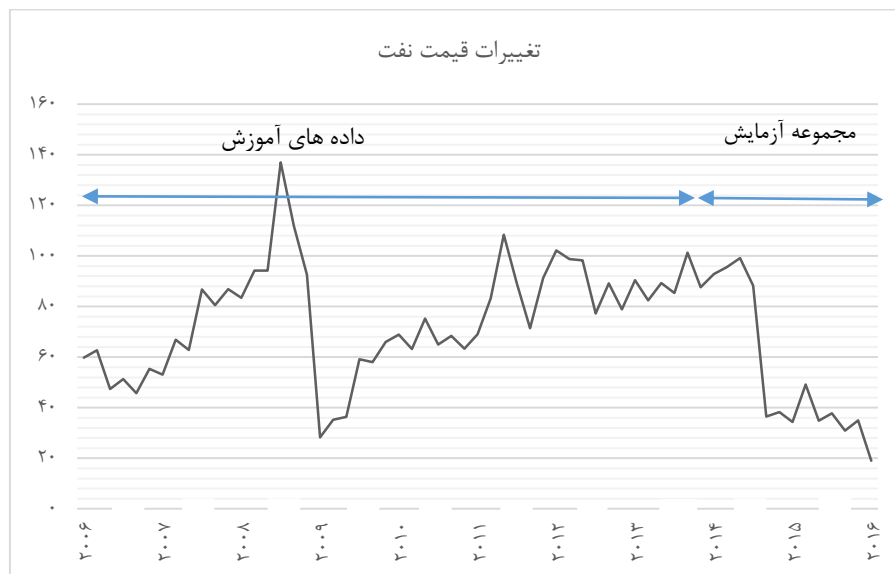
$$p = \frac{100}{N} \sum_{i=1}^n w_i \quad (۹)$$

$p$  پارامتری برای در نظر گرفتن مجموع مقادیر مختلف وزن دهی از طریق معماری‌های مختلف شبکه،  $N$  نشان‌دهنده تعداد نسل‌ها در الگوریتم ژنتیک و  $w_i$  وزن‌های حاصل از ورودی‌های شبکه عصبی مصنوعی می‌باشد، عدد ۱۰۰ نیز حداکثر تعداد نسل‌ها در الگوریتم ژنتیک می‌باشد (جدی و همکاران، ۲۰۱۵). از این‌رو برای تعیین معیارهای بهینه معماری شبکه عصبی مصنوعی، الگوریتم ژنتیک به‌طور هم‌زمان وزن‌ها و خطای ناشی از ساختار شبکه را با استفاده از معادلات ۳ و ۸ تعیین می‌کند. با در نظر گرفتن حداقل مقدار تابع برازندگی در حین اجرای الگوریتم شبکه با کمترین پیچیدگی و خطابه دست می‌آید.

#### ۴. داده‌های مدل

در این بخش از پژوهش قیمت نفت خام وست تگزاس اینترمدیت (WTI) از سال ۲۰۰۶ تا انتهای سال ۲۰۱۵ به‌صورت روزانه مورد استفاده قرار گرفته است. بدین ترتیب که داده‌های تغییرات قیمت نفت برای پنج روز کاری شامل ۲۳۴۰ داده برای پیش‌بینی، در نظر گرفته می‌شوند. این داده‌ها از سایت آژانس بین‌المللی انرژی<sup>۱</sup> استخراج شده‌اند، در مباحث مدل‌سازی، از ۲۳۴۰ داده بیان‌شده در نمودار شکل ۳، ۱۴۸۰ داده که بیانگر تغییرات قیمت نفت در سال‌های مورد نظر می‌باشد استخراج شده و جهت پیش‌بینی مورد استفاده قرار می‌گیرد. در این تحقیق برای معماری‌های مختلف شبکه عصبی، تعداد گره‌های ورودی برابر تعداد داده‌ها یعنی برابر با ۱۴۸۰ سطر و ۲ ستون می‌باشد.

1. International Energy Agency (IEA)



International Energy Agency (IEA)

شکل ۳: تغییرات قیمت نفت در سال‌های ۲۰۰۶ تا ۲۰۱۶

جدول ۳: نمایش مینیموم، ماکزیمم، میانگین، مد، میانه، انحراف معیار داده‌ها قیمت نفت

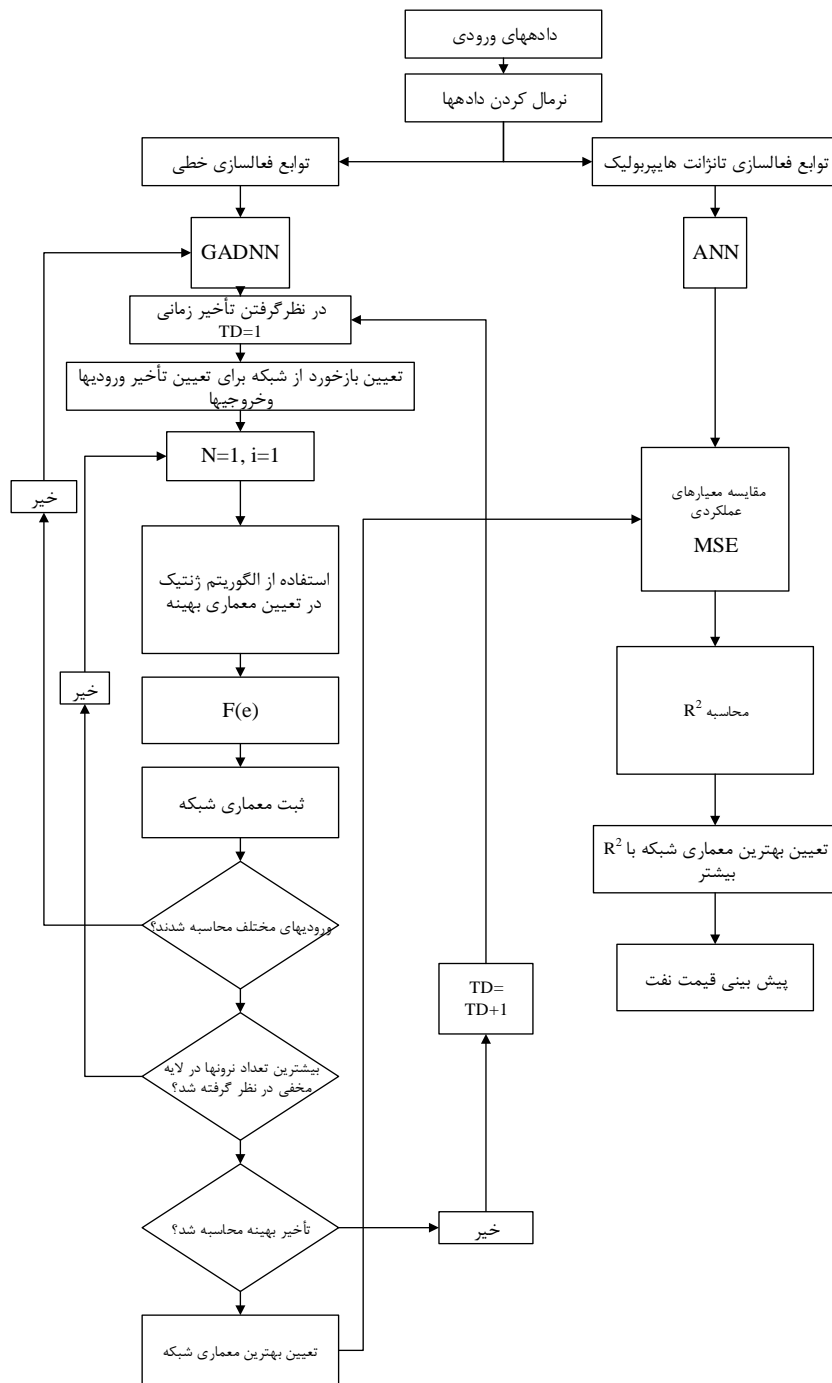
داده‌ها	مینیموم	ماکزیمم	میانگین	میانه	مد	انحراف معیار	کل داده‌ها
Y(قیمت)	۲۸,۳۱	۱۳۷	۷۱,۴۶	۷۱,۳۹	۶۹,۶۹۷	۲۴,۴۷	۲۳۴۰

همان‌طور که در جدول ۳ نشان داده شده است، بیشترین و کمترین قیمت نفت در این دوره به ترتیب برابر با ۲۸,۳۱ و ۱۳۷ دلار در هر بشکه هست فاصله زیاد حداقل و حداکثر قیمت نفت در طی دوره در نظر گرفته شده، همچنین انحراف معیار در این دوره که برابر ۲۴,۴۷ دلار در هر بشکه است، ماهیت پویای روند تغییرات قیمت نفت به صورت کامل نمایان می‌نماید، به همین جهت سعی در تخمین بهترین مدل برای پیش‌بینی قیمت خواهیم داشت تا علاوه بر پیش‌بینی، وقفه‌های بهینه ناشی از تغییرات قیمت نفت را نیز مشخص کند.

## ۵. مدل‌سازی

برای طراحی شبکه عصبی مصنوعی علاوه بر انتخاب مجموع داده‌های ورودی باید معیارهای بهینه معماری شبکه نیز مشخص شود. برای تعیین بهترین مدل در بررسی تغییرات قیمت نفت و پیش‌بینی صحیح آن بر اساس الگوریتم شکل ۴ مدل‌هایی با فرض‌های:

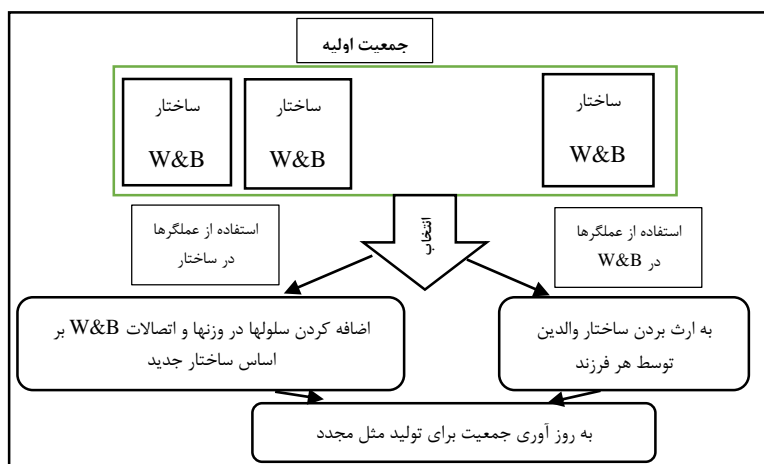
ورودی‌های نرمال شده با دو بازه متفاوت توابع فعال‌سازی خطی و تانژانت هایپربولیک در لایه‌های پنهان برای هر دو شبکه به صورت مشترک در نظر گرفته شد. در تعیین متغیرهای شبکه عصبی مصنوعی علاوه بر فرض‌های بالا به تغییر تعداد لایه‌های پنهان بین ۱ تا ۳ لایه نیز پرداخته می‌شود. در این مقاله از روش آزمون و خطا برای تعیین معماری بهینه شبکه عصبی استفاده شده است. بدین ترتیب با در نظر گرفتن معماری‌های مختلف، پس از هر بار آموزش شبکه و تخمین وزن‌های شبکه، معیارهای عملکردی در مرحله آموزش و آزمایش مورد محاسبه قرار می‌گیرد.



شکل ۴: الگوریتم مدل‌سازی پژوهش

منبع: محاسبات محقق

در تعیین بهترین ساختار شبکه عصبی مصنوعی پویا با استفاده از الگوریتم ژنتیک از نکات مطرح شده در پژوهش جدی و همکاران (۲۰۱۵) بهره برده ایم؛ اما نکته قابل توجه این است که مدل آن‌ها وقفه‌های ورودی و خروجی بهینه را در طراحی شبکه و دریافت بازخورد از آن تعیین نکرده است. در این پژوهش، برای استفاده از GADNN در تعیین معماری بهینه شبکه عصبی مصنوعی، مدل با دریافت بازخورد از شبکه به محاسبه وقفه‌های ورودی و خروجی بهینه یعنی  $n_u$  و  $n_y$  می‌پردازد و پس از تعیین وقفه‌های ورودی و خروجی با محاسبه  $f(s)$ ، شبکه با کمترین پیچیدگی را مشخص می‌کند (شکل ۴). در GADNN، برای نشان دادن هر جواب یا راه‌حل از دو رشته کروموزوم تحت عنوان دو بردار یک‌بعدی استفاده می‌شود. از رشته اول برای تعیین ساختار شبکه عصبی و از بردار دوم برای نشان دادن وزن‌ها و اتصالات شبکه عصبی که به اختصار W&B، می‌نامیم استفاده می‌شود. در طراحی رشته‌ها و برای تعیین ساختار مناسب شبکه عصبی و ساختار W&B، ۳ رشته، شامل تعداد لایه‌های پنهان و ۳ رشته بعدی برای تعیین تعداد نرون‌ها در لایه‌های پنهان در نظر گرفته شده است. استفاده از الگوریتم ژنتیک در بهینه‌سازی پارامترهای شبکه عصبی در شکل ۵ نمایش داده شده است.



شکل ۵- مراحل الگوریتم ژنتیک در بهینه‌سازی شبکه عصبی

منبع: جدی و همکاران، ۲۰۱۵

با توجه به مراحل مختلف شکل ۴، معماری بهینه حاصل از هر دو شبکه عنوان شده تعیین می‌گردد. پس از محاسبه معیارهای عملکردی، ضریب تعیین مراحل مختلف  $R^2$  حاصل از تخمین به‌وسیله هر دو شبکه، برای مقایسه دقت پیش‌بینی در خروجی مدل‌ها طبق معادله ۱۰ محاسبه می‌شود:

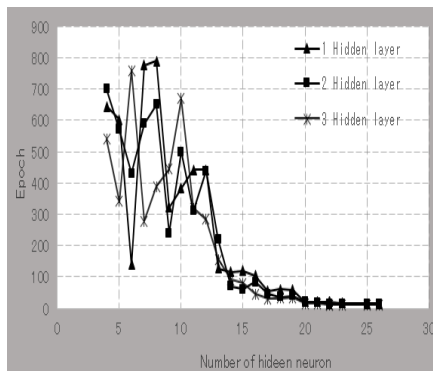
$$R^2 = 1 - \frac{\sum_1^N (y - \hat{y})^2}{\sum_1^N (y - \bar{y})^2} \quad (10)$$

که  $\bar{y}$  میانگین و  $y$  نشان‌دهنده تغییرات قیمت نفت در طول دوره مورد بررسی است. با استفاده از مقایسه ضریب تعیین که مقادیری بین صفر و یک را به خود اختصاص می‌دهد، به تعیین بهترین معماری حاصل از شبکه‌های عصبی در پیش‌بینی قیمت نفت می‌پردازیم. بدین ترتیب که هرچه  $R^2$  به یک نزدیک‌تر باشد، مدل از دقت بالاتری در پیش‌بینی برخوردار خواهد بود.

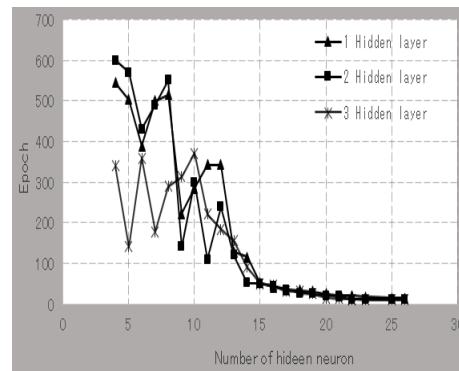
## ۶. نتایج پژوهش

ورودی‌های مسئله بر اساس داده‌های شکل و جدول ۳ برای مدل‌سازی توسط شبکه عصبی استفاده شدند، بدین ترتیب که داده‌ها به دو بخش مجزا، شامل ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد از داده‌ها برای مرحله آزمایش در نظر گرفته شدند. تابع فعال‌سازی خروجی از نوع خطی است. برای طراحی شبکه عصبی، از ورودی‌های نرمال شده در دو بازه  $[1 \text{ و } -1]$  و  $[10 \text{ و } -10]$  و تابع تانژانت هایپربولیک به‌عنوان تابع فعال‌سازی لایه پنهان استفاده می‌گردد.

برای تعیین تعداد بهینه لایه‌های پنهان و نرون‌ها در لایه پنهان با ورودی‌های مختلف در شبکه عصبی مصنوعی، از فرآیند آزمون و خطا استفاده می‌گردد. بدین صورت که تعریفی به‌عنوان دوره<sup>۱</sup> را مطرح می‌نماییم. یک دوره، متشکل از یک چرخه کامل به‌روزرسانی یادگیری، توسط داده‌های تعیین شده برای آموزش شبکه عصبی مصنوعی می‌باشد. به‌عنوان مثال ۱۰۰۰ دوره یعنی وزن‌های تعیین شده در مرحله آموزش ۱۰۰۰ دفعه به‌روزرسانی می‌گردند تا جایی که افزایش نرون‌ها در لایه‌های پنهان باعث افزایش تعداد دفعات به‌روزرسانی وزن‌ها نشده و خطای ناشی از آموزش شبکه به سمت عدد خاصی همگرا شوند. در نمودار شکل ۶ و ۷ محور افقی نشان‌دهنده افزایش تعداد نرون‌ها و محور عمودی تعداد دفعات را برای تعیین حداکثر نرون‌ها در لایه پنهان، نشان می‌دهد.



شکل ۷: تعداد نرون بهینه در لایه‌های پنهان نرمال شده در بازه  $[1 \text{ و } -1]$



شکل ۶: تعداد نرون بهینه در لایه‌های پنهان نرمال شده در بازه  $[10 \text{ و } -10]$

منبع: محاسبات محقق



همان‌طور که در شکل‌های ۶ و ۷ نمایش داده شده است. با افزایش نرون‌ها از یک حد خاص نیاز شبکه، برای به‌روزرسانی وزن‌ها، به سمت عدد خاصی میل می‌کند. این امر نشان‌دهنده این است که افزایش نرون‌ها در لایه پنهان لزوماً معیارهای عملکردی آموزش شبکه را در تعیین معماری بهینه کاهش نمی‌دهند و تعداد نرون‌های بهینه در لایه‌های پنهان تعیین شده‌اند. با این توضیحات، تعداد نرون‌های بهینه برای ۱، ۲ و ۳ لایه پنهان در معماری شبکه عصبی مصنوعی در جدول ۴ نمایش داده شده‌اند.

جدول ۴: نتایج حاصل از استفاده از معماری‌های مختلف شبکه عصبی در پیش‌بینی قیمت نفت

شماره	تعداد لایه‌های پنهان	نرمال‌سازی	تعداد نرون‌ها در لایه پنهان	فعال‌سازی تانزانت‌های پیربولیک		مدل بهینه
				MSE آموزش	MSE آزمایش	
۱	۱	[۱ و -۱]	۱۸	۲,۹۱۸۷	۳,۷۶۲	
۲	۲		۱۴	۲,۸۹۵۷	۳,۵۰۱	
۳	۳		۱۳	۲,۵۸۳	۳,۳۸۸	*
۴	۱	[۱۰ و -۱۰]	۲۰	۳,۸۷۶	۳,۸۹۰	
۵	۲		۱۸	۳,۶۰۲	۴,۲۱۶	
۶	۳		۱۲	۲,۷۵۳	۳,۵۵۲	

منبع: محاسبات محقق

با توجه به نتایج جدول ۴ و مقایسه میانگین خطا در مرحله آموزش و آزمایش، شبکه با سه لایه پنهان و ۱۳ نرون در لایه پنهان و داده‌های نرمال بین مقادیر [۱ و -۱] به‌عنوان معماری بهینه شبکه عصبی چندلایه پرسپترون در پیش‌بینی انتخاب می‌گردد.

برای طراحی شبکه عصبی GADNN از سه وقفه زمانی ۱ و ۲ و ۳ روزه برای تعیین وقفه‌های ورودی و دو وقفه ۲ و ۱ روزه برای تعیین وقفه‌های خروجی و دو تابع فعال‌سازی و نرمال‌سازی داده‌ها در بازه‌های مختلف بهره گرفته شد، با استفاده از وقفه‌های مختلف تابع برازندگی  $f(s)$ ، به‌طور هم‌زمان وزن‌ها و خطای ناشی از ساختار شبکه را با استفاده از معادلات ۳ و ۸ تعدیل می‌کند. برای در نظر گرفتن خطای  $\epsilon$  در تابع برازندگی از معیار MSE استفاده شده است.

شبکه با دریافت بازخورد از ورودی‌ها (الگوریتم شکل ۵) در هر مرحله اجرای الگوریتم، بیشترین نرون‌ها را در لایه پنهان در نظر می‌گیرد. در نظر گرفتن تعداد کم نرون‌ها در لایه فعال‌سازی، باعث می‌شود که شبکه نتواند رابطه میان ورودی‌ها و خروجی‌ها را به‌خوبی بیان کند و افزایش تعداد نرون‌ها شبکه را دچار خطا کرده مانع از یافتن نقطه کلی بهینه می‌گردد (شبکه در نقطه بهینه محلی متوقف می‌شود). بدین ترتیب باید حد بخصوصی را برای افزایش تعداد نرون‌ها در لایه پنهان در نظر گرفت؛ اما با افزایش تعداد نرون‌ها لزوماً خطا کاهش پیدا نمی‌کند به‌علاوه باعث افزایش زمان اجرای برنامه

می‌گردد. به همین جهت با استفاده از نتایج به‌دست‌آمده از شبکه عصبی مصنوعی پرسپترون حداکثر افزایش تعداد نرون‌ها در شبکه عصبی GADNN در لایه پنهان را با توجه به بیشترین مقدار محاسبه‌شده در جدول ۴، یعنی ۲۵ نرون در نظر می‌گیریم. با توجه به توضیحات ذکرشده، با استفاده از الگوریتم ژنتیک به بهینه‌سازی معماری شبکه عصبی مصنوعی می‌پردازیم. نتایج حاصل از توابع فعالسازی و ورودی‌های مختلف برای محاسبه تابع برازندگی در شبکه عصبی GADNN، به ترتیب در جدول ۵ و ۶ محاسبه‌شده است. شکل ۷ نیز مقادیر تابع برازندگی  $f(s)$  را برای معماری‌های مختلف عنوان شده در شبکه GADNN نشان می‌دهد.

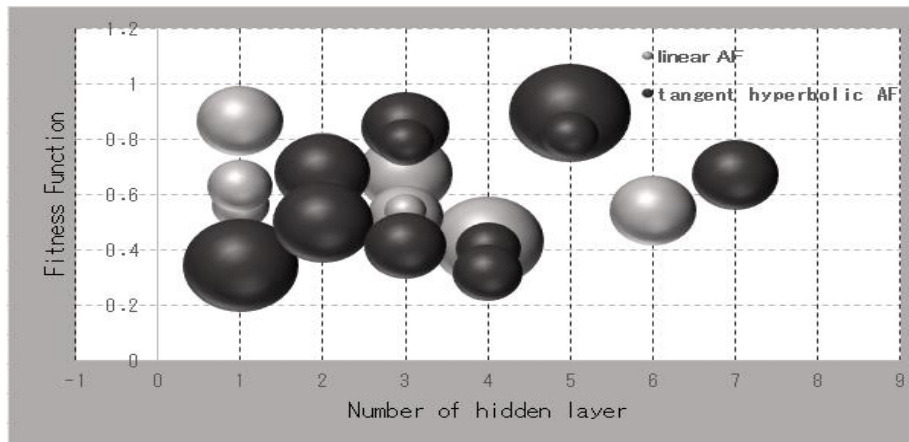
جدول ۵: استفاده از تابع فعال‌سازی خطی در GADNN

شماره	داده‌های ورودی	تأخیر در نظر گرفته‌شده ورودی	تأخیر در نظر گرفته‌شده خروجی	تعداد لایه پنهان	تعداد نرون‌های در لایه‌های پنهان	$f(s)$
۱	نرمال‌سازی [۱ و -۱]	۱	۱	۱	۹	۰.۸۶۵
			۲	۳	۱۱	۰.۶۷۸
۲	نرمال‌سازی [۱ و -۱]	۲	۱	۲	۸	۰.۶۷۳
			۲	۴	۱۵	۰.۷۳۲
۳	نرمال‌سازی [۱ و -۱]	۳	۱	۲	۶	۰.۷۲۳
			۲	۵	۶	۰.۸۹۰
۴	نرمال‌سازی [۱۰ و -۱۰]	۱	۱	۱	۴	۰.۵۶۲
			۲	۳	۷	۰.۵۲۳
۵	نرمال‌سازی [۱۰ و -۱۰]	۲	۱	۱	۳	۰.۴۲۳
			۲	۶	۹	۰.۵۴۲
۶	نرمال‌سازی [۱۰ و -۱۰]	۳	۱	۱	۵	۰.۶۳۰
			۲	۳	۲	۰.۵۴۰

جدول ۶: استفاده از تابع فعال‌سازی تانژانت هایپربولیک در GADNN

شماره	داده‌های ورودی	تأخیر در نظر گرفته‌شده ورودی	تأخیر در نظر گرفته‌شده خروجی	تعداد لایه پنهان	تعداد نرون‌های در لایه‌های پنهان	$f(s)$
۱	نرمال‌سازی [۱ و -۱]	۱	۱	۲	۱۱	۰.۶۷۹
			۲	۳	۹	۰.۸۴۳
۲	نرمال‌سازی [۱ و -۱]	۲	۱	۱	۱۶	۰.۳۴۴
			۲	۲	۱۲	۰.۵۰۱
۳	نرمال‌سازی [۱ و -۱]	۳	۱	۴	۵	۰.۴۰۵
			۲	۳	۴	۰.۷۸۹
۴	نرمال‌سازی [۱۰ و -۱۰]	۱	۱	۴	۳	۰.۳۲۷
			۲	۵	۱۸	۰.۸۹۶
۵	نرمال‌سازی [۱۰ و -۱۰]	۲	۱	۷	۹	۰.۶۷۱
			۲	۵	۴	۰.۸۱۳
۶	نرمال‌سازی [۱۰ و -۱۰]	۳	۱	۲	۵	۰.۳۱۷
			۲	۴	۸	۰.۴۱۸

منبع: محاسبات محقق



شکل ۷: نمودار حاصل از تابع برازندگی در استفاده از الگوریتم ژنتیک

منبع: محاسبات محقق

در نمودار شکل ۷، کره‌های مشکی نشان‌دهنده استفاده از تابع فعال‌سازی تانژانت هایپربولیک در لایه‌های پنهان و کره‌های خاکستری استفاده از تابع خطی فعال‌سازی را نشان می‌دهند. تعداد لایه‌های پنهان در محور افقی و مقادیر تابع برازندگی در محور عمودی نشان داده شده‌اند. همچنین اندازه هر کره نشان‌دهنده تعداد نرون‌ها در لایه پنهان می‌باشد؛ یعنی کره‌هایی با حجم بیشتر نرون‌های بیشتری در لایه‌های پنهان دارند. بعد از ۳۰ بار اجرای برنامه در محیط نرم‌افزار متلب، با استفاده از مقادیر به‌دست‌آمده برای تابع برازندگی در هر مرحله از الگوریتم ژنتیک و مقایسه آن‌ها در جداول ۵ و ۶ در بین فرض‌های در نظر گرفته شده، شبکه‌ای انتخاب می‌گردد که کمترین میزان تابع برازندگی  $f(s)$  را در خروجی نشان دهد که به صورت پررنگ در جدول ۶ نشان داده شده است. تعداد لایه‌های پنهان ۲ و تعداد ۵ نرون در لایه پنهان به‌عنوان پارامترهای شبکه عصبی اصلاح‌شده با الگوریتم ژنتیک تعیین شد که با توجه به شبکه عصبی پرسپترون از پیچیدگی کمتری برخوردار است.

تابع فعال‌سازی بهینه به‌دست‌آمده از میان دو تابع مختلف در نظر گرفته شده، تانژانت هایپربولیک می‌باشد که کمترین میزان تابع برازندگی را در صورت نرمال‌سازی داده‌ها بین مقادیر  $[-10, 10]$  با ۵ نرون در لایه پنهان به‌خود اختصاص داده است. بدین ترتیب: تعداد وقفه‌های بهینه عبارت‌اند از ۳ وقفه، در داده‌های ورودی  $(u(t-3), u(t-2), u(t-1))$  و یک وقفه در خروجی داده‌ها  $y(t-1)$  که برای محاسبه خروجی  $y(t)$  استفاده می‌شوند. در نتیجه بر اساس معادله ۵ تابع تعیین خروجی‌های شبکه عبارت‌اند از:


$$\hat{y}_t = f(u(t), u(t-1), u(t-2), u(t-3), y(t), y(t-1))$$

با به دست آمدن معماری بهینه حاصل از شبکه عصبی پرسپترون و شبکه عصبی اصلاح‌شده با استفاده از الگوریتم ژنتیک به تخمین نمودارهای حاصل از پیش‌بینی قیمت نفت با استفاده از هر دو مدل می‌پردازیم. بدین ترتیب دو مدل با معماری‌های مختلف بر اساس پارامترهای نشان داده شده در جدول ۷ برای پیش‌بینی قیمت نفت استفاده می‌گردند. نمودارهای حاصل از پیش‌بینی توسط مدل ۱ و ۲ به ترتیب در شکل ۸-الف و ۸-ب نمایش داده شده‌اند. بعد از تعیین نمودارهای پیش‌بینی به وسیله دو مدل برای بررسی دقت مدل بهینه در پیش‌بینی به محاسبه ضریب تعیین  $R^2$  حاصل از هر دو مدل در پیش‌بینی می‌پردازیم که نتایج در جدول ۸ نشان داده شده‌اند.

جدول ۷: معماری‌های بهینه حاصل از دو مدل شبکه عصبی

شماره	شبکه	تعداد لایه‌های پنهان	تعداد نرون‌ها در لایه‌های پنهان	تابع فعال‌سازی	دامنه نرمال‌سازی
مدل ۱	ANN	۳	۱۳	تانژانت هایپربولیک	[۱ و -۱]
مدل ۲	GADNN	۲	۵	تانژانت هایپربولیک	[۱۰ و -۱۰]

منبع: محاسبات محقق



شکل ۸-ب: استفاده از مدل ۲ در پیش‌بینی قیمت نفت



شکل ۸-الف: استفاده از مدل ۱ در پیش‌بینی قیمت نفت

منبع: محاسبات محقق

جدول ۸: مقایسه نتایج حاصل از استفاده از مدل‌های شبکه عصبی مصنوعی

مدل بهینه	%R <sup>2</sup>	MSE		رویکرد	منبع
		آزمایش	آموزش		
	۹۰	۳,۳۸۸	۲,۵۸۳	MLP	مدل ۱
*	۹۸	۱,۳۶۷	۰,۹۵۱	GADNN	مدل ۲
	۷۲	-	۳,۳۵	GA-NN	امین ناصری و قراچه (۲۰۰۷)
	۹۱	-	۰,۰۰۰۰۰۱۳۱۹۷	GA-NN	چيروما و همکاران (۲۰۱۵)
	۹۰	-	-	MLP	عباسی گودرزی و همکاران (۲۰۱۴)

منبع: محاسبات محقق

با توجه به نتایج مربوط به ارزیابی ضریب عملکرد در پیش‌بینی توسط رویکردهای مختلف استفاده از شبکه عصبی مصنوعی، همان‌طور که از مقادیر نشان داده شده در جدول ۸ مشخص است، ملاحظه می‌گردد که معماری بهینه حاصل از شبکه عصبی مصنوعی اصلاح‌شده با الگوریتم ژنتیک (مدل ۲) از ضریب تعیین  $R^2$  بالاتری نسبت به مدل ۱ (شبکه عصبی مصنوعی چند لایه) و سایر معماری‌های بهینه شبکه عصبی مصنوعی در پیش‌بینی قیمت نفت برخوردار است ( $R^2 = 98\%$ ). به علاوه مدل شبکه عصبی اصلاح‌شده با الگوریتم ژنتیک با در نظر گرفتن وقفه‌های بهینه در پیش‌بینی باعث افزایش دقت در پیش‌بینی نیز می‌گردد. نتایج مربوط به MSE مرحله آموزش مدل ۲ در مقایسه با نتایج پژوهش چیروما و همکاران (۲۰۱۵) از مقادیر بالاتری برخوردار است که این امر به دلیل تفاوت‌های ناشی از تابع برازندگی مختلف در تعیین معماری بهینه شبکه عصبی توسط الگوریتم ژنتیک در پیش‌بینی می‌باشد (مدل پیشنهادی تابع برازندگی را بر اساس درصد اتصالات (کاهش پیچیدگی) و میانگین مربعات خطای شبکه عصبی در مرحله آموزش محاسبه نموده اما تابع برازندگی پژوهش‌های چیروما و همکاران (۲۰۱۵) فقط بر اساس میانگین مربعات خطای شبکه محاسبه می‌گردد). با توجه به آن چه که بیان شد و بررسی نتایج حاصل از معیارهای عملکردی استفاده از شبکه عصبی در پیش‌بینی نتیجه می‌شود، استفاده از مدل شبکه عصبی اصلاح‌شده با الگوریتم ژنتیک GADNN دقت در پیش‌بینی قیمت نفت را افزایش داده و خطای حاصل از پیش‌بینی را در مقایسه با سایر معماری‌های شبکه عصبی مصنوعی در پیش‌بینی کاهش می‌دهد.

## ۷. نتیجه‌گیری

مطالعات بسیاری برای پیش‌بینی قیمت نفت صورت گرفته است که ناشی از اهمیت تعیین قیمت این کالای در مبادلات اقتصادی دارد. به همین جهت تلاش برای افزایش دقت در طراحی مدل‌های مختلف پیش‌بینی، بدیهی به نظر می‌رسد. همانند سایر مدل‌های تجربی، شبکه‌های عصبی ممکن است با داده‌های ورودی و معماری‌های مختلف ساخته شوند اما تعیین معماری بهینه، از بین مدل‌های مختلف پیچیدگی‌های ناشی از استفاده از شبکه عصبی را افزایش خواهد داد. در این تحقیق، از دو مدل شبکه‌های عصبی چندلایه پرسپترون و شبکه عصبی پویا اصلاح‌شده با الگوریتم ژنتیک بهره برده شد. شبکه‌های عصبی پویا برخلاف شبکه‌هایی عصبی مصنوعی ایستا، توانایی در نظر گرفتن زمان و وقفه‌های ورودی و خروجی را در پیش‌بینی قیمت نفت را دارند. همین امر سبب افزایش دقت در پیش‌بینی به وسیله این مدل‌ها می‌گردد که با استفاده از طراحی الگوریتمی در این تحقیق وقفه‌های ورودی و خروجی محاسبه شدند. همچنین، طبق مطالعه انجام‌گرفته استفاده از الگوریتم ژنتیک برای بررسی هم‌زمان ساختار و تعیین وزن‌ها و تعداد گره‌ها در شبکه عصبی باعث بهبود در معیارهای عملکردی شبکه عصبی شده و ضریب تعیین  $R^2$  را افزایش خواهد داد. با توجه به کارایی استفاده از روش GADNN برای پیش‌بینی

قیمت نفت، برای مطالعات آینده می‌توان از ورودی‌های مختلف تأثیرگذار مانند میزان مصرف انرژی، میزان تولید انرژی، میزان ذخیره‌سازی نفت و ... به‌عنوان ورودی‌های مختلف شبکه عصبی مصنوعی در پیش‌بینی استفاده نمود.

## منابع

- ابریشمی، حمید؛ بهرام‌مهر، نفیسه و سیفی، طاهره (۱۳۹۲). «پیش‌بینی قیمت نفت خام با استفاده از تبدیل موجک، مدل‌های غیرخطی و مدل‌های خطی»، فصلنامه مطالعات اقتصادی کاربردی ایران، ۲(۷)، ۴۱-۶۲.
- اصفهانیان، مجید و امین ناصری، محمدرضا (۱۳۸۷). «ارائه یک مدل شبکه عصبی جهت پیش‌بینی کوتاه‌مدت قیمت نفت خام»، نشریه بین‌المللی علوم مهندسی دانشگاه علم و صنعت ایران، شماره ۱، جلد ۱۹، ۲۵-۳۷.
- پورکاظمی، محمدحسین و اسدی، محمدباقر (۱۳۸۸). «پیش‌بینی پویای قیمت نفت خام با استفاده از شبکه‌های عصبی مصنوعی و با به‌کارگیری ذخیره‌سازی‌های نفتی کشورهای OECD»، مجله تحقیقات اقتصادی، شماره ۸۸، ۲۵-۳۶.
- جوانمرد، حبیب‌اله و فقیدیان، سیده فاطمه (۱۳۹۳). «پیش‌بینی قیمت نفت خام اوپک با به‌کارگیری مدل پیش‌بینی خاکستری»، فصلنامه مدل‌سازی اقتصادی، سال هشتم، شماره ۳، پیاپی ۲۷، ۹۱-۱۱۴.
- دشتی رحمت‌آبادی، سید ابراهیم؛ محمدی، حمید و فرج‌زاده، زکریا (۱۳۹۰). «ارزیابی عملکرد الگوهای مختلف شبکه عصبی و خود رگرسیون میانگین متحرک در پیش‌بینی قیمت نفت خام ایران»، فصلنامه مطالعات اقتصاد انرژی، سال هشتم، شماره ۲۸، دوره اول، ۹۷-۱۱۸.
- صادقی، حسین؛ ذوالفقاری، مهدی و الهامی‌نژاد، مجتبی (۱۳۹۰). «مقایسه عملکرد شبکه عصبی و ARIMA در مدل‌سازی پیش‌بینی کوتاه‌مدت قیمت سبب نفت خام اپک (با تأکید بر مطالعات تطبیقی)»، فصلنامه مطالعات اقتصادی ایران، سال هشتم، شماره ۲۸، ۲۵-۴۷.
- عباسی‌نژاد، حسین؛ گندلی علیخانی، نادیا و نادری، اسماعیل (۱۳۹۲). «تحلیل و پیش‌بینی اثرات غیرخطی در بازار نفت»، فصلنامه برنامه‌ریزی بودجه، سال هجدهم، شماره ۳، ۲۱-۴۸.
- کمیجانی، اکبر؛ نادری، اسماعیل و گندلی علیخانی، نادیا (۱۳۹۱). «مقایسه انواع مدل‌های واریانس ناهمسان شرطی در مدل‌سازی و پیش‌بینی نوسانات قیمت نفت»، فصلنامه مطالعات اقتصاد انرژی، سال نهم، شماره ۳۵، دوره چهارم، ۱۲۱-۱۴۶.
- گلستانی، شهرام؛ گرگینی، مصطفی و حاج عباسی، فاطمه (۱۳۹۱). «مقایسه توانایی پیش‌بینی مدل‌های VAR، ARIMA و شبکه‌های عصبی (ANN) تقاضای جهانی نفت اوپک»، فصلنامه اقتصاد محیط زیست و انرژی، سال اول، شماره ۴، ۱۴۵-۱۶۸.
- مشیری، سعید و فروتن، فائزه (۱۳۸۳). «آزمون آشوب و پیش‌بینی قیمت‌های آتی نفت خام»، پژوهش‌های اقتصادی ایران، دوره ۶، شماره ۲۱، ۶۷-۹۰.
- منجمی، امیرحسین؛ ابزری، مهدی و رعیتی شوازی، علیرضا (۱۳۸۸). «پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک و مقایسه آن با شبکه عصبی مصنوعی»، فصلنامه اقتصاد مقداری (بررسی‌های اقتصادی سابق)، دوره ۶، شماره ۳، ۱-۲۶.
- مهرگان، نادر و سلمانی، یونس (۱۳۹۳). «نوسانات قیمتی نفت و رشد پایدار اقتصادی: مطالعه‌ی موردی ایران و ژاپن»، فصلنامه علمی - پژوهشی مطالعات اقتصادی کاربردی ایران، دوره ۳، شماره ۱۰، ۱۰۷-۱۲۵.
- یوسفی، محمدقلی؛ محمدی، تیمور و معرف‌زاده، نوید (۱۳۹۲). «پیش‌بینی مقدار تقاضای نفت خام ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN) و مدل ARMAX»، فصلنامه اقتصاد انرژی ایران، سال دوم، ۷(۲)، ۱۴۷-۱۷۰.

- Abbasi-Godarzi, A.; Madadi-Amiri, R.; Talaei, A. and Jamasb, T. (2014). "Predicting oil price movements: A dynamic Artificial Neural Network approach". *Energy Policy* Vol. 68, 371-382.
- Abramson, B. and Finizza, A. J. (1993). "A Belief Network-Based System that Forecasts the Oil Market by Constructing Producer Behavior". In *Proceedings of the 15th North American Conference of the International Association for Energy Economics*: 152-159.
- Alexandridis, A. and Livanis, E. (2008). "Forecasting crude oil prices using wavelet neural networks". *Proceedings of the 5th FSDET*.
- Alizadeh, A. and Mafinezhad, K. (2010). "Monthly Brent oil price forecasting using artificial neural networks and crisis index". In *Electronics and Information Engineering (ICEIE), 2010 International Conference*, 2, V2-465.
- Amin-Naseri, M. R. and Gharacheh, E. A. (2007). "A hybrid artificial intelligence approach to monthly forecasting of crude oil price time series". Paper presented at the *The Proceedings of the 10th International Conference on Engineering Applications of Neural Networks*, CEUR-WS284.
- Azadeh, A.; Moghaddam, M.; Khakzad, M. and Ebrahimipour, V. (2012). "A flexible neural network-fuzzy mathematical programming algorithm for improvement of oil price estimation and forecasting". *Computers & Industrial Engineering*, 62(2), 421-430.
- Boroushaki, M.; Ghofrani, M.B.; Lucas, C. and Yazdanpanah, M. J. (2003); "Identification and control of an nuclear reactor core (VVER) recurrent neural networks and fuzzy system", *IEEE Trans. Nucl.Sci*, Vol. 50, 74-159.
- Chalup, S., Maire, F. (1999); "A study on hill climbing algorithms for neural network training, *Evolutionary Computation*, CEC 99, Vol. 2023.
- Chiroma, H., Abdulkareem, S., & Herawan, T. (2015). "Evolutionary Neural Network model for West Texas Intermediate crude oil price prediction". *Applied Energy*, 142, 266-273.
- Dreyfus, G. (2005). "Neural Networks Methodology and Applications". Springer. *Expert systems with application*, 38, 10210-10217.
- Gujarati, D.N. and Madsen, J. (1998). "Basic econometrics". *Journal of Applied Econometrics*. Vol. 13, 209-212.
- Haupt, R. L. and Haupt, S. E. (1996). "Practical Genetic Algorithms". Second Edition, A JOHN WILEY & SONS, INC., PUBLICATION.
- Haidar, I.; Kulkarni, S. and Pan, H. (2008). Forecasting model for crude oil prices based on artificial neural networks. Paper presented at the *Intelligent Sensors, Sensor Networks and Information Processing*, 2008. ISSNIP 2008. International Conference on.
- Jaddi, N. S.; Abdullah, S. and Hamdan, A. R. (2015). "A Solution representation of genetic algorithm for neural network weights and structure". *Information Processing Letters*.
- Jaddi, N.S.; Abdullah, S. and Hamdan, A. R. (2013); "Taguchi-Based Parameter Designing of Genetic Algorithm for Artificial Neural Network Training", *Informatics and Creative Multimedia (ICICM), International Conference on*, IEEE, 278-281.



- Jammazi, R. and Aloui, C. (2012). "Crude oil price forecasting: experimental evidence from wavelet decomposition and neural network modeling". *Energy Econ*, Vol. 34, 828-841.
- Jinn-Tsong, T.; Jyh-Horng, C. and Tung-Kuan, L. (2006). "Tuning the structure and parameters of a neural network by using hybrid Taguchi-genetic algorithm", *IEEE Transactions on Neural Networks*, Vol. 17, 69-80.
- Kyoung, J. and Han, I. (2003). "Application of a hybrid genetic algorithm and neural network approach in activity-based costing", *Expert systems with application*, 24, 73-77.
- Lee, S. and Hyunchul, A. (2011). "The hybrid model of neural networks and genetic algorithms for the design of controls for internet based systems for business-to-consumer electronic commerce". *Expert systems with application*, 38, 4326-4338.
- Lackes, R.; Börgermann, C. and Dirkmorfeld, M. (2009). "Forecasting the price development of crude oil with artificial neural networks *Distributed Computing, Artificial Intelligence, Bioinformatics, Soft Computing, and Ambient Assisted Living* (pp. 248-255): Springer.
- Ludermir, T.B.; Yamazaki, A. and Zanchettin, C. (2006). "An Optimization Methodology for Neural Network Weights and Architectures", *Trans Neur Net*, Vol. 17 (6), 1452-1459.
- Mokhatab Rafiei, F.; Manzari, S.M. and Bostanian, S. (2011). "Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminate analysis: Iranian evidence". *Journal of Expert Systems with Applications*. Vol 38, 10210-10217.
- Morana, C. (2001). "A Semi Parametric Approach to Short-Term Oil Price Forecasting". *Energy Economics*, Vol. 23, 325-338.
- Mostafa, M. M. and El-Masry, A. A. (2016). "Oil price forecasting using gene expression programming and artificial neural networks". *Economic Modelling*, 54, 40-53.
- Movagharnejad, K.; Mehdizadeh, B.; Banihashemi, M. and Kordkheili, M.S. (2011). "Forecasting the differences between various commercial oil prices in the Persian Gulf region by neural network". *Energy*, Vol. 36, 3979-3984.
- Norgaard, M.O.; Ravn, N. and Poulsen, L. (2000). "Hansen, *Neural Networks for Modelling and Control of Dynamic Systems*". Springer.
- Oh, S. K. and Pedrycz, W. (2005). "A new approach to self-organizing fuzzy polynomial neural networks guided by genetic optimization", *Physics Letters A*, Vol. 345, 88-100.
- Oh, S. K.; Pedrycz, W. and Roh, S. B. (2009). "Hybrid fuzzy set-based polynomial neural networks and their development with the aid of genetic optimization and information granulation", *Applied Soft Computing*, Vol. 9: 1068-1089.
- Pan, H.; Haidar, I. and Kulkarni, S. (2009). "Daily prediction of short-term trends of crude oil prices using neural networks exploiting multimarket dynamics". *Frontiers of Computer Science in China*, 3(2), 177-191.
- Sexton, R. S.; Alidaee, B.; Dorsey, R. E. and Johnson, J. D. (1998). "Global optimization for artificial neural networks: A tabu search application", *European Journal of Operational Research*, 106, 570-584.

- Sexton, R. S.; Dorsey R. E. and Johnson, J. D. (1999). "Optimization of neural networks: A comparative analysis of the genetic algorithm and simulated annealing", *European Journal of Operational Research*, 114, 589-601.
- Wang, Y.; Liu, L.; Diao, X. and Wu, C. (2015). "Forecasting the real prices of crude oil under economic and statistical constraints", *Energy Economics*, Vol. 51, 599-608.
- Wu, L. and Shahidpour, M. (2010). "A Hybrid Model for Day – Ahead Price Forecasting". *IEEE Transaction on Power Systems*, Vol. 25, No 3.
- Zanchettin, C.; Ludermir, T.B. and Almeida, L.M. (2011). "Hybrid Training Method for MLP: Optimization of Architecture and Training", *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, Vol. 41 (4), 1097-1109.