

## پیش‌بینی قیمت گاز طبیعی با استفاده از ترکیب تبدیل موجک و

### شبکه عصبی مصنوعی

### (مطالعه موردی: بازار آمریکا)<sup>۱</sup>

تیمور محمدی<sup>۲</sup>

عاطفه تکلیف<sup>۳</sup>

ساحل زمانی<sup>۴</sup>

تاریخ پذیرش: ۹۵/۱۰/۱۲

تاریخ ارسال: ۹۴/۹/۴

### چکیده

در این مقاله تلاش شده است با استفاده از ترکیب تبدیل موجک و شبکه عصبی مدلی به‌منظور پیش‌بینی روزانه قیمت گاز طبیعی ارائه شود. در این مدل ترکیبی، از موجک گسسته دابیشز به‌منظور تجزیه سری زمانی قیمت استفاده شده، سپس ضرایب تقریبی و جزئیات مؤثر به‌عنوان ورودی شبکه عصبی به‌منظور پیش‌بینی قیمت گاز طبیعی هنری هاب به‌عنوان مرجعی برای قیمت گاز طبیعی در آمریکا به‌کار رفته است. مقایسه عملکرد نسبی مدل ترکیبی با مدل شبکه عصبی حاکی از آن است که مدل ترکیبی تبدیل موجک و شبکه عصبی عملکرد پیش‌بینی را در مقایسه با مدل شبکه عصبی بهبود بخشیده است. آزمون دیولد - ماریانو نیز این نتیجه را تأیید کرده است.

واژگان کلیدی: تبدیل موجک، پیش‌بینی قیمت گاز طبیعی، شبکه عصبی مصنوعی

طبقه‌بندی JEL: C53, C59, Q47

۱- مقاله برگرفته از پایان‌نامه کارشناسی ارشد رشته اقتصاد انرژی در دانشکده اقتصاد دانشگاه علامه طباطبائی است، که با حمایت و پشتیبانی شرکت ملی گاز ایران انجام شده است.

۲- دانشیار، گروه اقتصاد نظری، دانشگاه علامه طباطبائی، پست‌الکترونیکی: atmahmadi@gmail.com

۳- استادیار، گروه اقتصاد انرژی، دانشگاه علامه طباطبائی، پست‌الکترونیکی: at.taklif@gmail.com

۴- کارشناس ارشد علوم اقتصادی دانشگاه علامه طباطبائی (نویسنده مسئول)، پست‌الکترونیکی:

Sahel.zamani@gmail.com

## ۱- مقدمه

انرژی نقش حیاتی در ساختار زیربنایی صنعت و اقتصاد ایفا می‌کند. در میان انرژی‌های گوناگونی که امروزه استفاده می‌شود با توجه به کاهش ذخایر نفتی و ملاحظات زیست محیطی سهم گاز طبیعی در سبد مصرف انرژی در حال افزایش است. بر اساس چشم‌انداز جهانی انرژی (۲۰۱۵)، که توسط آژانس بین‌المللی انرژی (IEA)<sup>۱</sup> منتشر می‌شود، برخلاف اروپا، که اوج مصرف را در سال ۲۰۱۰ تجربه کرد، طی دوره ۲۰۱۵ تا ۲۰۴۰ رشد تقاضای گاز طبیعی در میان سوخت‌های فسیلی بسیار چشمگیر است. ۴۷ درصد رشد تقاضا از سوی چین و کشورهای خاورمیانه خواهد بود. در این دوره، قیمت‌های ارزان گاز طبیعی یکی از چالش‌های اساسی در تصمیمات سرمایه‌گذاری در صنعت سرمایه‌بر نفت و گاز است، هرچند تولید گاز طبیعی افزایش یافته و در سال ۲۰۴۰ به حدود ۵/۲ تریلیون مترمکعب خواهد رسید. ۶۰ درصد تجارت منطقه‌ای انرژی در آسیا مربوط به تجارت گاز طبیعی خواهد بود، این در حالی است که سهم نفت خام و زغال‌سنگ به ترتیب ۷۵ درصد و ۸۰ درصد است. صادرات گاز طبیعی آمریکای شمالی به حدود ۸۵ میلیارد مترمکعب در سال ۲۰۳۵ افزایش خواهد یافت و این منطقه به لحاظ نفت خام تا نیمه ۲۰۲۰ خودکفا خواهد شد. واردات گاز طبیعی اروپا نیز از منابع متنوع‌تر وارداتی صورت خواهد گرفت و حجم واردات این منطقه ۳۰ درصد افزایش خواهد یافت.

طبق پیش‌بینی‌ها تقاضای گاز طبیعی در چین از حدود ۱۳۰ میلیارد مترمکعب در سال ۲۰۱۱ به ۵۴۵ میلیارد مترمکعب در سال ۲۰۳۵ افزایش می‌یابد. همچنین، مصرف گاز طبیعی در خاورمیانه و هند نیز به ترتیب به ۶۴۰ میلیارد مترمکعب و ۱۸۰ میلیارد مترمکعب در سال ۲۰۳۵ افزایش می‌یابد (چشم‌انداز جهانی انرژی، ۲۰۱۱). قیمت ارزان و عرضه فراوان گاز طبیعی در آمریکا به معنای سبقت گرفتن گاز طبیعی از نفت و تبدیل آن به بزرگ‌ترین سوخت، در ترکیب انرژی جهان، در سال ۲۰۳۰ است.

مطالعه و پیش‌بینی قیمت‌های فروش گاز بر اساس داده‌های واقعی و اطلاعات بازار و نیز

1 - World Energy Outlook 2015, International Energy Agency

با استفاده از رویکردهای مدل‌سازی و پیش‌بینی کارا می‌تواند در کشورهای دارای منابع نفت و گاز مفید واقع شود. در کشور ما که توسعه صادرات گاز که همواره به‌عنوان یکی از برنامه‌های وزارت نفت مدنظر است مستلزم برنامه‌ریزی و بهینه‌یابی تخصیص گاز بر اساس پیش‌بینی قیمت گاز و یا تحولات تقاضای گاز در بازارهای هدف در آینده است. طرح‌های سرمایه‌گذاری در صنعت نفت و گاز زمان‌بر و بسیار سرمایه‌بر است، بنابراین تصمیم‌گیری در خصوص اجرای یک طرح، نیازمند مطالعه و بررسی همه جوانب، به‌ویژه مسائل اقتصادی، است. هرچند بازار گاز هنوز مانند بازار نفت خام جهانی نشده و اغلب منطقه‌ای است؛ زیرا حمل و نقل گاز طبیعی به‌آسانی انتقال نفت و یا با هزینه کمتر از انتقال نفت نیست، اما به هر حال تغییرات قیمت در یک منطقه بر جهت‌گیری سرمایه‌گذاری در مناطق دیگر اثرگذار است. مثلاً، قطر در سال‌های گذشته، سرمایه‌گذاری در خور توجهی در صادرات LNG به آمریکا انجام داده بود، اما با توسعه گاز شیل در آمریکا، قیمت LNG صادراتی قطر به آمریکا تا یک‌سوم کاهش یافت. بنابراین، تمرکز بیشتر قطر بر بازار اروپا معطوف شد. توسعه سرمایه‌گذاری یک رقیب در یک منطقه، بر قیمت‌های صادراتی سایر رقبا تأثیرگذار است. قطعاً توجه بیشتر قطر به بازار اروپا بر تصمیمات قیمتی روسیه و تصمیمات سرمایه‌گذاری ایران در بازار اروپا در خصوص صادرات گاز تأثیرگذار بوده است. از این رو، به‌دلیل ارتباط نزدیک بازارهای نفت و گاز، بررسی مدل‌های پیش‌بینی قیمت در بازارهای دیگر و تحولات تقاضا نقش مؤثری بر برنامه‌ریزی صحیح انرژی در کشور ما دارد.

در دهه اخیر، مدل‌های کلاسیک سری زمانی همانند الگوی خود رگرسیون میانگین متحرک<sup>۱</sup> و الگوی اتورگرسیو واریانس ناهمسان شرطی<sup>۲</sup> تعمیم‌یافته<sup>۳</sup> به‌منظور پیش‌بینی قیمت نفت و گاز مورد توجه زیادی قرار گرفته‌اند، اما مدل‌های نامبرده زمانی می‌تواند پیش‌بینی خوبی ارائه دهند که سری زمانی مورد مطالعه خطی یا نزدیک به خطی باشد. به عبارت دیگر، این مدل‌ها توانایی محدودی در پیش‌بینی داده‌های غیرخطی و ناماننا<sup>۳</sup> دارند.

1 -Autoregressive Moving Average (ARMA)

2 -Generalized Autoregressive Conditional Heteroskedastic (GARCH)

3 -Nonstationary

شبکه عصبی مصنوعی (ANN)<sup>۱</sup> توانایی بسیاری در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی دارد (هرچند انتقاداتی نیز به آن وارد است)، در حالی که این توانایی برای مدل‌های معمول کلاسیک به‌سختی امکان‌پذیر است. مطالعات متعددی با استفاده از مدل شبکه عصبی مصنوعی به پیش‌بینی قیمت نفت و گاز پرداخته‌اند. نتایج این مطالعات حاکی از آن است که مدل شبکه عصبی مصنوعی عملکرد پیش‌بینی بهتری در مقایسه با مدل‌های کلاسیک ارائه می‌دهد. با وجود توانایی بسیار شبکه عصبی مصنوعی در پیش‌بینی، عملکرد آن در برخی موقعیت‌های خاص متناقض است و قواعد مشخصی برای طراحی شبکه به‌منظور یک کاربرد اختیاری وجود ندارد (شبری و سامسودین<sup>۲</sup>، ۲۰۱۴، ص ۱). همچنین، در مدل‌سازی صرفاً نمی‌توان با استفاده از شبکه عصبی به فیزیک مسئله پی برد. به عبارت دیگر، مرتبط کردن پارامترها یا ساختار شبکه به پارامترهای فرایند معمولاً غیرممکن است. علاوه بر این، شبکه عصبی مصنوعی سری‌های زمانی خام را به‌عنوان سیگنال ورودی دریافت می‌کند و آینده را پیش‌بینی می‌کند، اما وجود نویز در داده‌های سری زمانی به‌طور جدی بر روی صحت پیش‌بینی اثر خواهد گذاشت. برای حل این مشکل، مدل‌های مبتنی بر نویززدایی موجک پیشنهاد می‌شود.

تبدیل موجک توانایی بالایی در برخورد با سری‌های زمانی مانا و نامانا دارد، در حالی که شبکه عصبی مصنوعی در برخورد با داده‌های نامانا دارای محدودیت است (شبری و سامسودین، ۲۰۱۴، ص ۲). همچنین، الگوی موجک الگوهایی با هر نوع فراوانی و فرکانس را شناسایی و پیش‌بینی می‌کند در صورتی که این توانایی برای سایر تکنیک‌ها امکان‌پذیر نیست. بنابراین، برخلاف مدل‌های متداول که از دامنه کاربرد محدودی برخوردارند تبدیل موجک از دامنه کاربرد وسیعی برخوردار است و با توجه به نامانا بودن سیکل‌های اقتصادی و متغیرها در ایران، بنابراین کاربرد موجک می‌تواند در مقایسه با مدل‌های کلاسیک سری زمانی و شبکه عصبی مفیدتر واقع شود.

1- Artificial Neural Network

2 -Shabri and Samsudin

اخیراً مدل‌های ترکیبی بر اساس تبدیل موجک به منظور پیش‌بینی قیمت پیشرفت‌های زیادی کرده است، اما در رابطه با پیش‌بینی قیمت گاز طبیعی توجه اندکی به استفاده از ترکیب تبدیل موجک و شبکه عصبی مصنوعی شده است. از این رو، بر آن شدیم تا در این مقاله به پیش‌بینی قیمت گاز طبیعی در هنری هاب به عنوان مرجعی برای قیمت گاز طبیعی در آمریکا با استفاده از مدل ترکیبی تبدیل موجک و شبکه عصبی مصنوعی پردازیم. برای این منظور، قیمت روزانه گاز طبیعی هنری هاب با استفاده از موجک گسسته دابیشز تجزیه شده است. سپس، با به دست آوردن ضریب تعیین بین ضرایب تجزیه شده و داده‌های اصلی، ضرایب تقریبات<sup>۱</sup> و جزئیات<sup>۲</sup> مؤثر مشخص شده و به عنوان ورودی مدل شبکه عصبی مصنوعی استفاده می‌شود. همچنین، عملکرد پیش‌بینی مدل ترکیبی با مدل شبکه عصبی مصنوعی مقایسه شده و آزمون دیبولد - ماریانو به منظور صحت پیش‌بینی استفاده شده است.

با توجه به مباحث فوق‌الذکر و آشنایی با اهمیت موضوع، در بخش دوم به مروری بر پیشینه تحقیقات انجام گرفته می‌پردازیم. بخش‌های سوم و چهارم به بیان نظری شبکه عصبی و تبدیل موجک اختصاص دارد. در بخش پنجم داده‌های مورد نیاز معرفی می‌شود. بخش‌های ششم و هفتم به برازش مدل شبکه عصبی و مدل ترکیبی می‌پردازند. در بخش هشتم به مقایسه صحت پیش‌بینی پرداخته می‌شود، و در پایان نتیجه‌گیری و پیشنهادات حاصل از انجام پژوهش ارائه می‌شود.

## ۲- پیشینه تحقیق

در این بخش به بررسی مطالعات انجام شده در حوزه پیش‌بینی قیمت نفت و گاز می‌پردازیم؛ از جمله:

شبری و روهدا<sup>۳</sup> (۲۰۱۴) با ترکیب تبدیل موجک و شبکه عصبی به پیش‌بینی

1 - Approximation

2 - Details

3 - Shabri and Ruhaidah

قیمت نفت خام برنت و وست تگزاس پرداخته‌اند. در این مطالعه ابتدا داده‌های سری زمانی قیمت نفت خام با استفاده از تبدیل موجک تجزیه و سپس این داده‌ها به‌عنوان ورودی شبکه عصبی مصنوعی استفاده شده‌اند. نتایج مطالعه آنها نشان می‌دهد که مدل ترکیبی تبدیل موجک و شبکه عصبی عملکرد مناسب‌تری در مقایسه با مدل شبکه عصبی، ARIMA و GARCH دارد. الکساندریاس و لیوانیس<sup>۱</sup> (۲۰۰۸) از ترکیب شبکه عصبی و موجک برای پیش‌بینی قیمت ماهانه نفت وست تگزاس اینترمدیت (WTI) استفاده کرده‌اند. برای این منظور از تبدیلات موجک به‌عنوان لگ‌های قیمتی استفاده شده است و در پایان به مقایسه نتایج مدل پیشنهادی با چشم‌انداز کوتاه‌مدت آژانس بین‌المللی انرژی (EIA's STEO) پرداختند که نتایج درخور توجهی به‌دست آوردند. امین ناصری و قراچه<sup>۲</sup> (۲۰۰۷) پیشنهاد مدل هوش مصنوعی ترکیبی به‌منظور پیش‌بینی قیمت ماهانه نفت خام با استفاده از شبکه‌های عصبی پیش‌خور، الگوریتم ژنتیک و خوشه‌بندی K-means را ارائه کردند. انگین و نابنی<sup>۳</sup> (۲۰۰۸) با استفاده از مدل ترکیبی تبدیل موجک و مدل‌های سری زمانی یادگیری تطبیقی به ارائه مدلی به‌منظور پیش‌بینی قیمت و تقاضای انرژی پرداخته‌اند. هی و همکاران (۲۰۱۲) به‌منظور بهبود دقت پیش‌بینی قیمت نفت خام از تبدیل موجک استفاده کرده‌اند. نتایج مطالعه آنها نشان می‌دهد این مدل علاوه بر پیش‌بینی دقیق‌تر امکان تحلیل بهتر بازار را نیز فراهم کرده است. یوسفی و همکاران<sup>۴</sup> (۲۰۰۵) یک روش پیش‌بینی مبتنی بر موجک برای پیش‌بینی در دوره‌های متفاوت قیمت نفت خام ارائه کرده‌اند. وانگ و همکاران<sup>۵</sup> (۲۰۰۴) از یک سیستم خبره شبکه‌ای مبتنی بر قانون استفاده کرده‌اند که این سیستم متشکل از تکنیک‌های اقتصادسنجی بود که پیش‌بینی را با

1 -Alexandridis and Livanis

2 -Amin-Naseri and Gharacheh

3 -Nguyen and Nabney

4 -He et al

5 -Yousefi et al

6 -S. Wang, L. Yu and K.K. Lai

استفاده از متدهای هوش مصنوعی انجام می‌داد. مقایسه معیار  $RMSE$  مدل اقتصادسنجی ARIMA و مدل مبتنی بر شبکه‌های عصبی نشان‌دهنده بهبود عملکرد مدل مبتنی بر شبکه‌های عصبی مصنوعی است. جامازی و الوی<sup>۱</sup> (۲۰۱۲) با استفاده از روش‌های ترکیبی مبتنی بر تجزیه موجک به پیش‌بینی قیمت نفت خام پرداخته‌اند.

از جمله مطالعات داخلی نیز می‌توان به این موارد اشاره کرد:

بهراد مهر (۱۳۸۷) از خاصیت هموارسازی تبدیل موجک برای کاهش سطح نویز داده‌ها استفاده کرده، سپس به وسیله شبکه عصبی مصنوعی و داده‌های هموارسازی شده، قیمت نفت را پیش‌بینی کرده است که موجب بهبود عملکرد پیش‌بینی در مقایسه با مدل‌های رقیب شده است. ابریشمی و همکاران (۱۳۹۲) با استفاده از مدل ترکیبی تبدیل موجک و مدل‌های ARMAX، رگرسیون هارمونیک و مدل هلت - وینترز به پیش‌بینی قیمت نفت خام پرداخته‌اند. آنها ابتدا داده‌های سری زمانی قیمت نفت خام را با استفاده از تبدیل موجک به سه سری داده‌های دارای روند، داده‌های متأثر از عوامل فصلی و داده‌های با فرکانس بالا (تلاطمات) تجزیه کرده، سپس هر سری با استفاده از مدل مربوط به آن پیش‌بینی شده و در نهایت برای دستیابی به پیش‌بینی نهایی سری‌های زمانی با هم ترکیب شده‌اند. نتایج این مطالعه نشان می‌دهد که مدل ترکیبی الگوی مناسب‌تری برای پیش‌بینی دقیق‌تر قیمت نفت خام ارائه می‌دهد و این الگو در مقایسه با مدل ARMA خطای پیش‌بینی ( $RMSE$ ) کمتر و دقت بیشتری دارد.

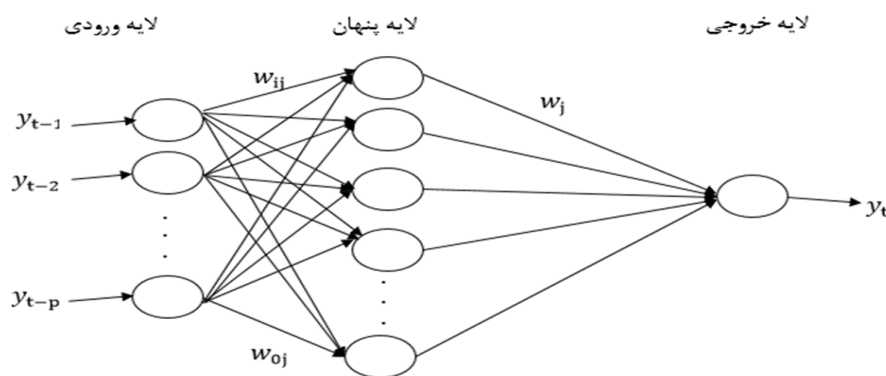
### ۳- شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی از اوایل دهه ۱۹۹۰ به‌طور گسترده برای پیش‌بینی سری‌های زمانی در علوم مختلف و مهندسی استفاده شده‌اند. الگوهای شبکه عصبی از جمله مدل‌های ریاضی هستند که از ذهن انسان شبیه‌سازی شده‌اند و کاربردهای

1 -Jammazi and Aloui

متفاوتی از قبیل طبقه‌بندی داده‌ها، تقریب توابع، پیش‌بینی متغیرها، خوشه‌بندی و بهینه‌سازی دارند.

شبکه عصبی مصنوعی معمولاً از ۳ لایه تشکیل شده است. لایه اول، لایه ورودی، شامل بردار متغیرهای مستقل (ورودی)، لایه دوم، لایه پنهان، شامل توابع عملگر، نورون‌های پردازش‌کننده داده‌های ورودی و لایه سوم، لایه خروجی، شامل برآورد (پیش‌بینی) بردار متغیر هدف (وابسته) است (بهرادمهر، ۱۳۸۸، ص ۹۰). شکل (۱) شبکه عصبی مصنوعی پیشنهاد شده برای پیش‌بینی قیمت گاز طبیعی را نشان می‌دهد.



شکل ۱- شبکه عصبی مصنوعی ۳ لایه

رابطه بین متغیر هدف ( $y_t$ ) و متغیرهای مستقل ( $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ ) از رابطه ۱ به دست می‌آید:

$$y_t = b_0 + \sum_{j=1}^q b_j f(w_{0j} + \sum_{i=0}^p w_{ij} y_{t-i}) + \varepsilon_{t_{it}} \quad (1)$$

$$(i = 0, 1, 2, \dots, p; j = 0, 1, 2, \dots, q)$$

$w_{ij}$  نشان‌دهنده وزنی است که ورودی  $i$  را به خروجی  $j$  ارتباط می‌دهد.  $p$  تعداد نورون‌های ورودی،  $q$  تعداد نورون‌های پنهان و  $f(\cdot)$  تابع تبدیل<sup>۱</sup> است (شبری و

1- Transfer Function



سامسودین، ۲۰۱۴، ص ۲).

برای اینکه خروجی خالص شبکه یا نورون متناسب و یا متناظر با خروجی مطلوب باشد معمولاً تابع مانند  $f$  بر آن تأثیر داده می‌شود. این توابع رابطه میان ورودی‌ها و خروجی‌های یک نورون و یک شبکه را تعیین می‌کنند. به‌طور کلی، توابع تبدیل درجه‌ای از وضعیت غیرخطی بودن را که برای بسیاری از کاربردهای شبکه مناسب است معرفی می‌کنند. در تئوری هر تابع قابل مشتق‌گیری می‌تواند یک تابع تبدیل باشد، اما در عمل تعداد معدودی از توابع خوش رفتار (یعنی محدود، اکیداً صعودی و مشتق‌پذیر) به‌عنوان توابع تبدیل استفاده می‌شود. در اکثر مطالعات از تابع تانژانت هایپربولیک<sup>۱</sup> به‌عنوان تابع تبدیل لایه پنهان استفاده می‌شود، اما هیچ اجماع نظری برای تعیین تابع تبدیل لایه خروجی وجود ندارد (شبری و سامسودین، ۲۰۱۴، ص ۳).

در این مقاله از تابع تانژانت هایپربولیک به‌عنوان تابع تبدیل لایه پنهان و تابع خطی به‌عنوان تابع تبدیل لایه خروجی استفاده شده است. روابط ۲ و ۳ این توابع را نشان می‌دهند:

$$f(s) = \frac{e^s - e^{-s}}{e^s + e^{-s}} \quad (2)$$

$$f(s') = s' \quad (3)$$

برای یادگیری وزن‌های یک شبکه (یا تخمین ضرایب شبکه) دو روش کلی وجود دارد: روش گرادیان نزولی<sup>۲</sup> و روش جست‌وجو جامع<sup>۳</sup>. روش پس انتشار خطا (BP)<sup>۴</sup>، روش نیوتن<sup>۵</sup>، روش شبه‌نیوتن<sup>۶</sup>، روش لوبنبرگ - مارکوارت (LM)<sup>۷</sup> از روش‌های گرادیان نزولی و الگوریتم ژنتیک GA یک کاربرد از روش جست‌وجو جامع است. الگوریتم یادگیری پس انتشار خطا (BP) یکی از رایج‌ترین الگوریتم‌ها به‌منظور آموزش شبکه‌های

- 
- 1 -Hyperbolic Tangent Function
  - 2 -Gradient-Descent Method
  - 3 -Global Search Method
  - 4 -Backpropagation
  - 5 -Newton Method
  - 6 -Quasi-NEWTON Method
  - 7 -Levenberg- Marquant Method

عصبی است که در واقع به کارگیری مستقیم الگوریتم گرادیان نزولی است. این الگوریتم ممکن است برای همگرا شدن به یک مقدار مینیمم زمان زیادی لازم داشته باشد (شبری و سامسودین، ۲۰۱۴، ص ۴).

و اگر در سطح خطا چندین مینیمم محلی وجود داشته باشد تضمینی وجود ندارد که الگوریتم به مینیمم مطلق یا جواب بهینه رسیده باشید. همچنین، این الگوریتم به نرخ یادگیری نیز بسیار حساس است. انتخاب نرخ یادگیری مناسب دشوار است؛ زیرا نرخ یادگیری کم منجر به طولانی شدن زمان یادگیری و نرخ یادگیری زیاد ممکن است منجر به بی‌ثباتی سیستم شود (میر و دندی، ۲۰۰۰).

برای غلبه بر ضعف‌های الگوریتم پس انتشار خطا در بسیاری از مطالعات از الگوریتم لونیبرگ - مارکوارت (LM) استفاده شده است. الگوریتم لونیبرگ - مارکوارت روشی استاندارد برای حل مسئله حداقل مربعات برای توابع غیرخطی و یکی از رایج‌ترین و کاراترین روش‌های بهینه‌سازی غیرخطی است. در این مقاله نیز به منظور آموزش شبکه عصبی از الگوریتم لونیبرگ - مارکوارت استفاده شده است.

#### ۴- تبدیل موجک

تبدیل موجک یک ابزار قوی ریاضی است که یک سری زمانی مانا یا نامانا را به دو بخش تقریبات و جزئیات تقسیم می‌کند، که این موضوع موقعیت مدل‌سازی جداگانه هر یک از بخش‌های هر سری زمانی یعنی تقریبات و جزئیات را در مدلی واحد فراهم می‌آورد. تحلیل موجک ابزار بسیار قدرتمندی است که می‌توان از آن برای بررسی اطلاعات کیفی سری‌های زمانی بسیار نامانا استفاده کرد. تبدیل موجک با استفاده از توابع پایه‌ای، یک سری زمانی را به فضای فرکانس می‌برد و سپس سری زمانی را در زمان و مقیاس‌های مختلف نشان می‌دهد. برخلاف تبدیل فوریه که تابع سینوس تنها تابع پایه‌ای است، تبدیل موجک، توابع پایه‌ای (موجک) پیوسته و ناپیوسته متفاوتی دارد، اما همه این توابع انرژی

محدودی دارند. این خاصیت موجک‌ها سبب می‌شود که این تبدیل، توانایی بررسی سری‌های نامتناه و زودگذر را داشته باشد. در فضای موجک، تابع پایه‌ای «موجک مادر» نامیده می‌شود و مابقی توابع پایه‌ای از بسط و گسترش موجک مادر تولید می‌شوند (بهرادمهر، ۱۳۸۸، ص ۸۵). تبدیل موجک قابلیت استفاده برای هر دو سری‌های زمانی پیوسته و گسسته را دارد، به همین منظور این تبدیلات دارای دو نوع تبدیل موجک پیوسته  $(CWT)$  و تبدیل موجک گسسته  $(DWT)$  هستند؛ اگر تبدیل موجک پیوسته باشد می‌توان آن را به صورت زیر تعریف کرد:

$$W(u,s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \Psi\left(\frac{t-u}{s}\right) dt \quad (4)$$

$W(u,s)$  نشان‌دهنده ضرایب حاصل از استفاده تابع موجک پیوسته برای سری زمانی پیوسته است و سری زمانی تبدیل شده تابعی دو متغیره با متغیرهای  $u$  (معرف مکان موجک) و  $s$  (پارامتر اندازه) است. همچنین،  $x(t)$  بیانگر سری زمانی اصلی و  $\Psi(t)$  بیانگر موجک مادر پیوسته است (شبری و سامسودین، ۲۰۱۴، ص ۳).

هر نوع تابعی را نمی‌توان به عنوان تابع موجک مادر در نظر گرفت، بلکه باید دو شرط را تأمین کند؛ شرط اول، که شرایط پذیرفتگی موجک مادر است، این است که این تابع باید در رابطه (۵) صدق کند:

$$\int_{-\infty}^{\infty} \frac{|\Psi(f)|^2}{|f|} df < \infty \quad (5)$$

$f$  نشان‌دهنده فرکانس و  $\Psi(f)$  بیانگر موجک مادر است. این شرط بیان می‌کند که در آن میانگین توابع موجک برابر صفر است، در واقع می‌توان دید که  $\Psi(0) = 0$  است؛ چرا که در غیر این صورت مقدار انتگرال عبارت (۵) در فرکانس صفر ( $f=0$ ) بی‌نهایت خواهد شد. همچنین، شرط دومی که بر تابع موجک مادر اعمال می‌شود واحد بودن انرژی آن است، به این معنا که:

- 1- Continuous Wavelet Transforms
- 2- Discrete Wavelet Transforms

$$\int_{-\infty}^{\infty} |\Psi(t)|^2 dt = 1 \quad (۶)$$

اما آنچه گفته شد تنها شرط لازم است و نه کافی، که این همان ریشه نام‌گذاری موجک است؛ بدین معنا که تابعی است که نوسان می‌کند، اما مدت استمرار آن کوتاه است. در واقع، این شرط برای آن است که بتوان تابع اولیه را از تجزیه موجک مجدد توسط تبدیل موجک معکوس بازسازی کرد (ابریشمی و همکاران، ۱۳۹۲، ص ۴۸). در حالی که سری زمانی گسسته باشد باید از موجک گسسته مادر استفاده کرد. از جمله توابع مهم تبدیل موجک گسسته می‌توان به توابع هار<sup>۱</sup>، دابیشز<sup>۲</sup>، سیملت<sup>۳</sup>، کویفلت<sup>۴</sup>، میر<sup>۵</sup> اشاره کرد. به‌طور کلی، موجک گسسته مادر به‌صورت زیر تعریف می‌شود (شبری و سامسودین، ۲۰۱۴، ص ۴):

$$\Psi_{m,n} \left( \frac{t-u}{s} \right) = \frac{1}{\sqrt{s_0^2 \frac{m}{s}}} \Psi \left( \frac{t-nu_0s_0^m}{s_0^m} \right) \quad (۷)$$

$n$  بیانگر مکان موجک و  $m$  بیانگر اندازه موجک است. معمولاً برای ساده‌تر شدن  $s_0 = 2$  و  $u = 1$  در نظر می‌گیرند در این حالت موجک گسسته مادر به‌صورت زیر تعریف می‌شود:

$$W_{m,n} = 2^{-\frac{m}{2}} \sum_{t=0}^{N-1} \Psi(2^{-m}t - n)x(t) \quad (۸)$$

$W_{m,n}$  نشان‌دهنده ضرایب حاصل از استفاده تابع موجک گسسته برای سری زمانی گسسته در  $s=2^m$  و  $u=2^m \cdot n$  است. بر اساس نظریه ملات<sup>۶</sup> (۱۹۹۸)، یک سری زمانی  $x(t)$  می‌تواند به دو بخش تقریبات و جزئیات تجزیه شود. بنابراین، سری زمانی اصلی یک تابع گسسته با استفاده از معکوس تابع موجک به‌صورت زیر به‌دست می‌آید:

$$x(t) = T + \sum_{m=1}^M \sum_{t=0}^{2^M-m-1} W_{m,n} 2^{-\frac{m}{2}} \Psi(2^{-m}t - n) \quad (۹)$$

- 1 -Haar
- 2 -Daubichies
- 3 -Symlet
- 4 -Coiflet
- 5 -Meyer
- 6 -Mallat


که شکل ساده عبارت‌اند از:

$$x(t) = A_M(t) + \sum_{m=1}^M D_m(t) \quad (10)$$

$A_M(t)$  بیانگر بخش تقریبیات یا به بیان دیگر جزء هموارشده سری زمانی است و  $D_m(t)$  ( $m = 1, 2, \dots, M$ ) بیانگر جزئیات و یا نویز موجود در سری زمانی است.

### ۵- داده‌ها و مواد تحقیق

در این مقاله قیمت گاز طبیعی هنری هاب به‌عنوان مرجعی برای قیمت گاز طبیعی آمریکا به‌منظور آزمون مدل ترکیبی تبدیل موجک و شبکه عصبی انتخاب شده است. قیمت گاز طبیعی در هنری هاب آمریکا برای یک دوره تقریباً ۱۸ ساله از ۷ ژانویه ۱۹۹۷ تا ۱۱ مارس ۲۰۱۵ به‌صورت روزانه (پنج روز کاری در هفته) از سایت اداره اطلاعات انرژی آمریکا استخراج شده است و به‌عنوان داده استفاده شده است. ۷۰ درصد داده‌ها به‌منظور آموزش و ۳۰ درصد مابقی به‌منظور آزمون به‌صورت تصادفی انتخاب شده است. نمودار قیمت روزانه گاز طبیعی بازار هنری هاب آمریکا در شکل (۲) نمایش داده شده است:



شکل ۲- نمودار قیمت گاز طبیعی هنری هاب از ۷ ژانویه ۱۹۹۷ تا ۱۱ مارس ۲۰۱۵

در این مقاله، معیار جذر میانگین مربع خطا ( $RMSE$ )<sup>۱</sup> به‌منظور ارزیابی دقت و صحت

1 -Root Mean Squared Error

مدل استفاده شده است:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (11)$$

$\hat{y}_t$  و  $y_t$  به ترتیب مقادیر واقعی و پیش‌بینی شده در زمان  $t$  و  $n$  تعداد کل مشاهدات است. مدلی که خطای کمتری دارد توانایی پیش‌بینی بهتری دارد. به عبارت دیگر،  $RMSE$  کمتر بیانگر توانایی پیش‌بینی بالاتر مدل است.

### ۶- برآزش مدل شبکه عصبی مصنوعی

در ابتدا شبکه عصبی پرسپترون چند لایه<sup>۱</sup> بدون هیچ گونه پردازشی بر روی داده‌ها مورد استفاده قرار گرفته است. شبکه‌های پرسپترون چند لایه از نوع شبکه‌های عصبی پیش‌خورند که یکی از پرکاربردترین مدل‌های شبکه‌های عصبی مصنوعی در مدل‌سازی و پیش‌بینی عناصر اقلیمی است. در شبکه‌های پرسپترون چند لایه هر نورون در هر لایه به تمام نورون‌های لایه قبل متصل است (منهاج، ۱۳۸۴). در طراحی یک شبکه عصبی پرسپترون باید تعداد نورون‌های ورودی، تعداد لایه‌های پنهان و نورون‌های پنهان و تعداد نورون‌های خروجی تعیین شود.

در این مقاله، از ترکیب ۶ وقفه سری زمانی قیمت گاز طبیعی به‌مثابه ورودی استفاده شده است:

(i)  $y_{t-1}$ , (ii)  $y_{t-1}, y_{t-2}$ , (iii)  $y_{t-1}, y_{t-2}, y_{t-3}$ , (iv)  $y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}$ ,

(v)  $y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}, y_{t-5}$ , (vi)  $y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}, y_{t-5}, y_{t-6}$

همان‌طور که پیش‌تر اشاره شد، شبکه عصبی مصنوعی در برخورد با داده‌های ناماننا محدودیت دارد. از این رو، به‌منظور بررسی مانایی سری زمانی مورد مطالعه، از آزمون دیکی فولر تعمیم‌یافته استفاده شده است. نتایج آزمون ADF برحسب ضابطه شوارز بی‌زین (SBC) نشان می‌دهد که سری زمانی متغیر قیمت گاز طبیعی ماناست و به‌منظور پیش‌بینی با شبکه‌های عصبی مصنوعی مشکلی ایجاد نمی‌کند.

جدول ۱- نتایج مربوط به آزمون ریشه واحد دیکی فولر تعمیم یافته (ADF)

متغیر	آماره ADF	مقادیر بحرانی (سطح ۵٪ اطمینان)	Prob
$y_t$	-۳/۳۲	-۲/۸۶	۰/۰۱۴

مأخذ: محاسبات تحقیق

همچنین، به منظور بهبود مدل‌سازی شبکه، تمام داده‌های ورودی و هدف در بازه [۱]،  
[۱-] نرمال شده‌اند. انتخاب تعداد لایه‌های پنهانی مسئله بسیار مهمی است؛ زیرا تعداد زیاد  
این لایه‌ها عملکرد شبکه را کاهش می‌دهد. از نظر تئوریک، یک شبکه عصبی با دو لایه  
پنهان قادر است هر تابع غیرخطی را با یک درجه دلخواه دقت تخمین بزند.

بنابراین، دلیلی ندارد از شبکه‌های عصبی با بیش از دو لایه پنهان استفاده کنیم.  
علاوه بر این، ثابت شده است که تنها یک لایه پنهان برای تقریب هر شبکه عصبی پیچیده  
و غیرخطی با هر میزان دقت کافی است. بنابراین، شبکه عصبی مورد استفاده در این مدل  
نیز تنها یک لایه پنهان دارد.

موضوع مهم دیگر انتخاب تعداد بهینه نورون‌های پنهان در شبکه‌های عصبی است.  
اگر تعداد نورون‌ها خیلی کم باشد سیستم دچار خطای زیاد آموزش می‌شود و خطای  
زیاد تعمیم‌سازی در رابطه با کم‌برازشی روی خواهد داد. در مقابل، اگر تعداد  
نورون‌های پنهان خیلی زیاد باشد مدل ممکن است خطای آموزش کمی داشته باشد،  
ولی خطای تعمیم‌سازی زیادی در رابطه با بیش‌برازشی خواهد داشت. بری و لینوف  
(۱۹۹۷) ادعا کردند اگر تعداد نورون ورودی  $I$  باشد تعداد نورون‌های پنهان نباید بیش  
از  $2I$  باشد. همچنین، ادعا شده است تعداد نورون‌های پنهان برابر با  $2I+1$  است (شبری  
و سامسودین، ۲۰۱۴، ص ۴). بنابراین، از آنجا که قاعده مشخصی به منظور تعیین تعداد  
بهینه نورون‌های پنهان وجود ندارد، در این مدل تعداد نورون‌های پنهان از ۱ تا ۱۳  
افزایش یافته است.

تعداد نورون‌های خروجی بستگی به موضوع مورد مطالعه برای مسئله پیش‌بینی سری

زمانی، تعداد نورون‌های خروجی و افق پیش‌بینی دارد، که در این مدل تعداد نورون خروجی ۱ در نظر گرفته شده است.

بنابراین، از آنجا که قاعده مشخصی برای تعیین تعداد نورون‌های ورودی و پنهان وجود ندارد، تلاش شده است با استفاده از روش آزمون و خطا بهترین ترکیب انتخاب شود. برای این منظور، کد مربوط به آموزش و آزمون شبکه عصبی در نرم‌افزار متلب به گونه‌ای نوشته شده است که ابتدا با یک ورودی و تعداد نورون‌های متفاوت (از ۱ تا ۱۳) شبکه آموزش و آزمون شود و تعداد نورون پنهان بهینه مربوط به کمترین RMSE گزارش شود. اینوروند با تعداد نورون‌های ورودی متفاوت تکرار می‌شود تا بهترین ترکیب انتخاب شود. جدول (۲) عملکرد شبکه عصبی با تعداد نورون‌های ورودی و پنهان مختلف را نشان می‌دهد.

جدول ۲- نتایج عملکرد شبکه عصبی با تعداد نورون ورودی و پنهان مختلف

تعداد نورون ورودی	تعداد نورون پنهان	RMSE	
		آموزش	آزمون
۱	۲	۰/۰۳۴۶	۰/۰۲۶۵
۲	۷	۰/۰۳۳۰	۰/۰۲۶۷
۳	۹	۰/۰۳۲۲	۰/۰۲۵۲
۴	۴	۰/۰۲۸۵	۰/۰۲۴۷
۵	۱	۰/۰۲۸۷	۰/۰۲۶۶
۶	۵	۰/۰۲۸۹	۰/۰۲۵۸

مأخذ: محاسبات تحقیق

بر اساس معیار  $RMSE$  برای داده‌های آموزش و آزمون بهترین عملکرد دارای ۴ نورون در لایه ورودی و ۴ نورون در لایه پنهان و ۱ نورون در لایه خروجی (۴-۴-۱) است که در این حالت  $RMSE$  داده‌های آزمون برابر با ۰/۰۲۴۷ است.




### ۷- برآزش مدل ترکیبی تبدیل موجک و شبکه عصبی

در مدل ترکیبی تبدیل موجک و شبکه عصبی (WANN)<sup>۱</sup> به منظور بهبود دقت مدل، ابتدا سری‌های زمانی قیمت گاز طبیعی با استفاده از جعبه ابزار موجک در نرم‌افزار متلب تجزیه شده و سپس به عنوان ورودی شبکه عصبی استفاده شده است. در تبدیل موجک، از موجک داییشز<sup>۲</sup>، که عملکرد پیش‌بینی خوبی از خود نشان داده، به منظور تجزیه استفاده شده است. هنگام تجزیه موجک، انتخاب تعداد سطوح تجزیه مناسب مهم است. برای انتخاب تعداد سطوح تجزیه از فرمول زیر استفاده شده است (شبری و سامسودین، ۲۰۱۴، ص ۵):

$$L = \text{int} [\log (N)] \quad (۱۲)$$

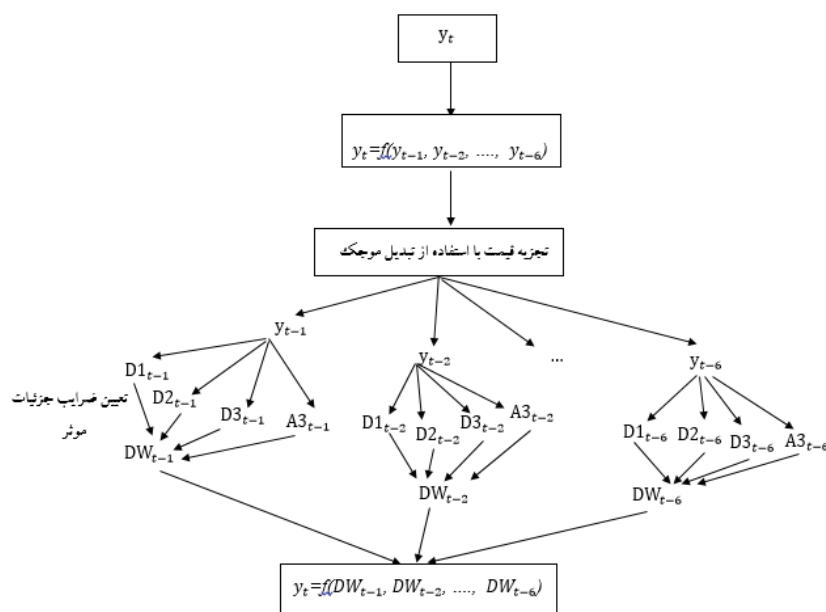
$L$  سطح تجزیه و  $N$  تعداد داده‌های سری زمانی است. بر اساس این فرمول تعداد سطوح تجزیه بهینه برای سری زمانی مورد مطالعه ۳ است. بنابراین، داده‌ها تا مرحله ۳ تجزیه شده و ضرایب جزئیات (D1, D2, D3) و تقریب (A3) به دست آورده شده است. شکل (۳) سیگنال نویززدایی شده و جزئیات را نشان می‌دهد.



شکل ۳- سیگنال نویززدایی شده و جزئیات

- 1- Wavelet And Artificial Neural Network
- 2- Daubechies Wavelet

هر یک از ضرایب جزئیات اثرات مختلفی بر سری زمانی قیمت گاز طبیعی دارد. بنابراین، به منظور افزایش عملکرد پیش‌بینی مدل ترکیبی به جای استفاده از ضرایب جزئیات به صورت جداگانه، مجموع ضرایب جزئیات به عنوان ورودی مدل استفاده شده است (شبری و سامسودین، ۲۰۱۴، ص ۶). شکل (۴) ساختار مدل ترکیبی تبدیل موجک و شبکه عصبی (WANN) را نشان می‌دهد.



شکل ۴- ساختار مدل ترکیبی تبدیل موجک و شبکه عصبی (WANN)

برای تعیین ارتباط بین ضرایب تجزیه شده و سری زمانی قیمت گاز طبیعی، ضریب تعیین ( $R^2$ ) محاسبه شده است. همان‌طور که در جدول (۳) نشان داده شده است، بین  $D1$  و سری زمانی قیمت گاز طبیعی ارتباط کمتری وجود دارد. بنابراین، با توجه به ضرایب تعیین ( $R^2$ ) محاسبه شده، مجموع ضرایب جزئیات ( $D2, D3$ ) و ضرایب تقریب ( $A3$ ) به عنوان ورودی مدل شبکه عصبی به منظور پیش‌بینی قیمت گاز طبیعی استفاده شده است ( $DW = A3 + D2 + D3$ ).

جدول ۳- ضریب تعیین ( $R^2$ ) بین ضرایب تجزیه شده و سری زمانی قیمت گاز طبیعی

DWT	t-1	t-2	t-3	t-4	t-5	t-6	Mean $R^2$
D1	۰/۰۰۲۸	۰/۰۰۳۵	۰/۰۰۲۸	۰/۰۰۳۵	۰/۰۰۳۵	۰/۰۰۳۵	۰/۰۰۳
D2	۰/۰۰۳۹	۰/۰۰۴۰	۰/۰۰۵۷	۰/۰۰۴۲	۰/۰۰۴۲	۰/۰۰۴۰	۰/۰۰۴
D3	۰/۰۰۵۷	۰/۰۰۵۲	۰/۰۰۴۸	۰/۰۰۶۰	۰/۰۰۶۰	۰/۰۰۶۲	۰/۰۰۵
A3	۰/۹۸۷۶	۰/۹۸۷۳	۰/۹۸۶۷	۰/۹۸۶۳	۰/۹۸۶۳	۰/۹۸۶۲	۰/۹۸۶

مأخذ: محاسبات تحقیق

مدل ترکیبی تبدیل موجک و شبکه عصبی همانند مدل شبکه عصبی آموزش دیده می شود با این تفاوت که داده های ورودی مدل ترکیبی تبدیل موجک و شبکه عصبی مجموع ضرایب جزئیات و تقریب (DW) است. نوروهای ورودی مدل WANN عبارت اند از:


- (i)  $DW_{t-1}$
- (ii)  $DW_{t-1}, DW_{t-2}$ ,
- (iii)  $DW_{t-1}, DW_{t-2}, DW_{t-3}$ ,
- (iv)  $DW_{t-1}, DW_{t-2}, DW_{t-3}, DW_{t-4}$ ,
- (v)  $DW_{t-1}, DW_{t-2}, DW_{t-3}, DW_{t-4}, DW_{t-5}$  and
- (vi)  $DW_{t-1}, DW_{t-2}, DW_{t-3}, DW_{t-4}, DW_{t-5}, DW_{t-6}$

همانند مدل شبکه عصبی ابتدا با یک ورودی و تعداد نوروهای متفاوت (از ۱ تا ۱۳) شبکه آموزش و آزمون می شود و تعداد نورو پنهان بهینه مربوط به کمترین  $RMSE$  گزارش می شود. اینوروند با تعداد نوروهای ورودی متفاوت تکرار می شود. جدول (۴) عملکرد شبکه عصبی با تعداد نورو ورودی و پنهان مختلف را نشان می دهد. بر اساس معیار  $RMSE$  برای داده های آموزش و آزمون بهترین عملکرد دارای ۴ نورو در لایه ورودی، ۸ نورو در لایه پنهان و ۱ نورو در لایه خروجی (۱-۸-۴) است، که در این حالت  $RMSE$  داده های آزمون برابر با ۰/۰۱۶۶ است.

جدول ۴- نتایج عملکرد مدل ترکیبی تبدیل موجک و شبکه عصبی با تعداد نورون ورودی و پنهان مختلف

تعداد نورون ورودی	تعداد نورون پنهان	RMSE	
		آموزش	آزمون
۱	۳	۰/۰۲۸۵	۰/۰۱۹۱
۲	۱۳	۰/۰۲۳۷	۰/۰۱۸۶
۳	۷	۰/۰۲۴۰	۰/۰۱۸۹
۴	۸	۰/۰۱۶۲	۰/۰۱۶۶
۵	۴	۰/۰۲۱۲	۰/۰۱۷۸
۶	۱۱	۰/۰۲۰۲	۰/۰۱۸۲

مأخذ: محاسبات تحقیق



شکل ۵- مقایسه قیمت پیش‌بینی شده و قیمت واقعی گاز طبیعی

با مقایسه نتایج عملکرد مدل ۲ مدل (مقایسه جدول ۲ و ۴) به‌طور کلی، مشاهده می‌شود عملکرد مدل ترکیبی تبدیل موجک و شبکه عصبی در مقایسه با مدل شبکه عصبی بهبود یافته است. این نتیجه بیانگر این است که نوین‌زدایی داده‌های ورودی توسط موجک اثر درخور توجهی بر نتایج مدل شبکه عصبی داشته است.

جدول ۵- مقایسه مدل ANN و WANN

مدل	RMSE
مدل شبکه عصبی (ANN)	۰/۰۲۴۷
مدل ترکیبی تبدیل موجک و شبکه عصبی (WANN)	۰/۰۱۶۶

مأخذ: محاسبات تحقیق

## ۸- مقایسه صحت پیش‌بینی

به منظور مقایسه صحت پیش‌بینی از آزمون دیبولد - ماریانو<sup>۱</sup> استفاده شده است. دیبولد و ماریانو (۱۹۹۵) نشان می‌دهند که قدرت پیش‌بینی یکسان تحت فرضیه  $DM \sim N(0,1)$  است. بنابراین، فرضیه قدرت پیش‌بینی یکسان در سطح ۹۵ درصد زمانی که  $DM > 1/96$  باشد رد می‌شود.

آماره دیبولد - ماریانو به صورت زیر به دست می‌آید:

$$DM = \frac{d}{\sqrt{V_d/F}} \quad (13)$$

$$d_t = \sum_{t=1}^F (d_t - WANN)^2 - \sum_{t=1}^F (d_t - ANN)^2 \quad (14)$$

$$d = (\sum_{t=1}^F d_t) / F \quad (15)$$

$$V_d = Y_0 + 2 \sum_{t=1}^{\infty} Y_t \quad (16)$$

$$Y_t = cov(d_t, d_{t-1}) \quad (17)$$

آزمون دیبولد - ماریانو را برای خطای پیش‌بینی مدل شبکه عصبی و مدل ترکیبی به کار برده شد<sup>۲</sup> و  $DM = 4/956$  به دست آمد. بنابراین، همان‌طور که نتایج آزمون نشان می‌دهد، در سطح اطمینان ۹۵ درصد قدرت پیش‌بینی مدل ترکیبی بهتر از مدل شبکه عصبی است و آزمون دیبولد - ماریانو صحت پیش‌بینی مدل ترکیبی را تأیید می‌کند.

1 -Diebold-Mariano

۲- آزمون دیبولد - ماریانو برای خطای پیش‌بینی مدل شبکه عصبی و مدل ترکیبی با استفاده از نرم‌افزار stata به کار برده شده است.

## ۹- نتیجه‌گیری

از آنجا که گاز طبیعی می‌تواند در برخی موارد جانشین مناسبی برای نفت خام باشد، از این رو به‌عنوان عنصری استراتژیک در آینده بازار انرژی مطرح می‌شود. بنابراین، پیش‌بینی قیمت و شناسایی روند تقاضای گاز طبیعی اجتناب‌ناپذیر است. تاکنون مدل‌های متفاوت و گوناگونی برای پیش‌بینی قیمت ارائه شده که تلاش همه مدل‌ها پیش‌بینی با خطای کمتر بوده است. در این مقاله با فرض اینکه اطلاعات بسیاری در قیمت گاز طبیعی نهفته است که می‌توان آنها را با بهره‌گیری از تبدیل موجک استخراج کرد، تلاش شده با استفاده از مدل ترکیبی تبدیل موجک و شبکه عصبی الگوی مناسب‌تری برای پیش‌بینی دقیق‌تر قیمت گاز طبیعی در مقایسه با مدل‌های پیشین ارائه کرد. برای این منظور، ابتدا سری‌های زمانی قیمت گاز طبیعی به‌وسیله تبدیل موجک تجزیه شد و بر اساس ضرایب همبستگی بین ضرایب تجزیه شده (تقریبات و جزئیات) و سری زمانی قیمت گاز طبیعی، ضرایب جزئیات مؤثر تشخیص داده شد، سپس مجموع ضرایب تقریبات و جزئیات مؤثر به‌عنوان ورودی شبکه عصبی استفاده شد. نتایج حاکی از آن است که بر اساس معیار خطای پیش‌بینی ( $RMSE$ ) عملکرد مدل ترکیبی تبدیل موجک و شبکه عصبی در مقایسه با مدل شبکه عصبی بهبود یافته است. این نتیجه بیانگر این است که نوپزرداری داده‌های ورودی توسط موجک اثر در خور توجهی بر نتایج مدل شبکه عصبی داشته است. همچنین، آزمون دیولد - ماریانو نیز این نتیجه را تأیید کرده است. توضیح لازم اینکه حاصل این مقاله یک تابع است که ضرایب آن توسط شبکه عصبی مصنوعی تعیین شده است. این تابع، با توجه به موارد ذکر شده در متن، قابلیت خوبی در زمینه پیش‌بینی دارد و در مقایسه با مطالعات انجام شده در گذشته، دقت بیشتری دارد.

## ۱۰- پیشنهادهایی برای مطالعات آتی

- در کشورهای مانند آمریکا و انگلستان با فراهم آوردن تمهیدات لازم؛ مثلاً خصوصی سازی، معاملات گاز در بورس‌های کاغذی، شفاف‌سازی قیمت و نظارت دقیق‌تر بر بازار گاز طبیعی؛ تلاش شده تا این بازار حالت رقابتی‌تر در مقایسه با گذشته پیدا کند

و قیمت گاز طبیعی تحت تأثیر تعاملات عوامل اقتصادی به خصوص عرضه و تقاضای گاز قرار بگیرد، اما تا به حال بازاری برای گاز ایران به شکل تعامل عوامل اقتصادی وجود نداشته است. با فراهم شدن امکان زیرساخت‌های لازم برای بازار داخلی گاز طبیعی می‌توان از مدل‌های پیش‌بینی قیمت در بازار داخلی نیز استفاده کرد.

- سیکل‌های اقتصادی و متغیرها در ایران مانا نیستند، بنابراین توسعه مدل‌های موجک که برای همه سیکل‌ها اعم از مانا و نامانا کاربرد دارد می‌تواند در مقایسه با مدل‌های کلاسیک سری زمانی و شبکه عصبی مفیدتر باشد.

- پیش‌بینی بهینه در مباحث پیش‌بینی متداول نیست، چون هر لحظه امکان معرفی مدل‌های بهتر وجود دارد. انتخاب مدل بهتر بر روی بحث  $RMSE$  متمرکز است. این مقاله نیز از همین سنت پیروی کرده است؛ به این صورت که با استفاده از مدل‌های مختلف پیش‌بینی انجام شده است و مدلی که  $RMSE$  کمتری داشته به‌عنوان مدل برتر انتخاب شده است. پیشنهاد می‌شود در مطالعات آتی از معیار دیگری مانند معیار ضریب نابرابری تایل (Theil) برای ارزیابی برتری تکنیک استفاده شود.

- در این مقاله تأثیر روی بازارها مدنظر نبوده است، چون بازارهای گاز منطقه‌ای بوده و امکان تأثیر بستگی به امکان ارتباط بازارها به یکدیگر دارد. از این رو، پیشنهاد می‌شود تعامل قیمت‌های Futures با پیش‌بینی قیمت اسپات و تأثیر متقابل آنها در این روش‌ها لحاظ شود.

## منابع

- ابریشمی، حمید؛ بهرام‌مهر، نفیسه و طاهره سیفی (۱۳۹۲). «پیش‌بینی قیمت نفت خام با استفاده از تبدیل موجک، مدل‌های غیرخطی و مدل‌های خطی»، فصل‌نامه مطالعات اقتصادی کاربردی ایران، سال دوم، شماره ۷، صفحات ۴۱-۶۲.
- بهرام‌مهر، نفیسه (۱۳۸۸). «پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و شبکه عصبی مصنوعی»، فصل‌نامه مطالعات اقتصاد انرژی، شماره ۱۸، صفحات ۸۱-۹۸.
- منهاج، محمدباقر (۱۳۸۱). مبانی شبکه‌های عصبی (هوش محاسباتی)، چاپ دوم، انتشارات دانشگاه صنعتی امیرکبیر.
- Alexandridis, A. Livanis, E., (2008). "Forecasting Crude Oil Prices using Wavelet Neural Networks", *5th Student Conference of Management Science and Technology (ΦΣΔΕΤ)*. Athnes, Greece (2008).
- Amin-Naseri, M.R. Gharacheh, E.A. (2007). "A Hybrid Artificial Intelligence Approach to Monthly Forecasting Oil Price Time Series". *Proceedings of EANN*.
- He. K, Yu. L, and Lai. K. K.,(2012). "Crude Oil Price Analysis and Forecasting Using Wavelet Decomposed Ensemble Model," *Energy*, Vol. 46, No. 1, PP. 564–574.
- Jammazi, R. Aloui, C. (2012), "Crude Oil Price Forecasting: Experimental Evidence from Wavelet Decomposition and Neural Network Modeling", *Energy Economics*, Vol. 34, No. 3, PP. 828–841.
- Maier, H.R. Dandy, G.C. (2000), "Neural Networks for the Prediction and Forecasting of Water Resources Variables: A Review of Modelling Issues and Applications", *Environmental Modelling and Software*, Vol.15, No. 1, PP. 101–124.
- Nguyen, H.T. Nabney,I.T., "Combining the Wavelet Transform and Forecasting Models to Predict Gas Forward Prices", 2008, Seventh International Conference on Machine Learning and Applications.
- Shabri, A. Samsudin, R, (2014), "Daily Crude Oil Price Forecasting Using Hybridizing Wavelet and Artificial Neural Network Model", *Hindawi Publishing Corporation Mathematical Problems Engineering*, Volume 2014, Article ID 201402, 10 pages.



- U.S. Energy Information Administration (<http://www.eia.gov>).
- Wang. S, Yu. L and Lai. K.K. (2004). "A Novel Hybrid AI System Framework for Crude Oil Price Forecasting". *Lecture Note in Computer Science*. Vol. 3327, PP. 203-242.
- World Energy Outlook 2012, International Energy Agency (IEA). (<http://www.iea.org>)
- Yousefi, S. Weinreich, I and Reinarz, D. (2005), "Wavelet-Based Prediction of Oil Prices", *Chaos, Solitons and Fractals*, vol. 25, no. 2, pp.265–275.