

پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و شبکه عصبی مصنوعی

نفیسه بهرادمهر

دکتری اقتصاد از دانشگاه نیویورک و مدرس دانشکده اقتصاد دانشگاه تهران

nbehradmehr@yahoo.com

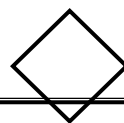
تاریخ دریافت: ۸۸/۳/۱۸ تاریخ پذیرش: ۸۸/۵/۱۸

چکیده

در این مقاله تلاش شده است تا با استفاده از تبدیل موجک و شبکه عصبی مدلی ارائه شود که پیش‌بینی دقیق‌تر و با خطای کم‌تری از قیمت نفت خام داشته باشد. در این مدل ترکیبی، از خاصیت هموارسازی تبدیل موجک برای کاهش سطح نویز داده‌ها استفاده شده و سپس به وسیله شبکه عصبی مصنوعی و با داده‌های هموار سازی شده، قیمت نفت پیش‌بینی شده است. نتایج حاصل از مقایسه RMSE مدل‌های رقیب با مدل ترکیبی مورد اشاره، دلالت بر آن دارد که کاهش نویز و هموار سازی داده‌ها، عملکرد پیش‌بینی قیمت نفت را بهبود می‌دهد.

طبقه‌بندی JEL: Q47 , C45 , C67

کلید واژه: تبدیل موجک، قیمت نفت خام، پیش‌بینی، هموار سازی، شبکه عصبی مصنوعی.



۱- مقدمه

انرژی یک کالای استراتژیک در سطوح بین المللی محسوب می‌شود و فعالیت دولت‌ها و سازمان‌ها، مؤثر و وابسته به این کالا و بازارهای مربوط به آن است. اتخاذ هر نوع سیاست توسط دولت‌ها و سازمان‌های بین‌المللی در زمینه انرژی، بحران‌های بازارهای مالی و حتی تغییرات شدید جوی می‌تواند اثرات مستقیم و غیرمستقیمی بر روی عرضه و تقاضای انرژی و در نتیجه قیمت این کالا بگذارد. هرگونه تغییر در قیمت انرژی، بر روی قیمت سایر کالاها و همچنین سبد مصرفی خانوارها و در کل رفاه جامعه تأثیرگذار است. از آنجایی که نفت خام اصلی‌ترین نوع انرژی است، اهمیت تأثیرگذاری قیمت آن در بخش‌های مختلف اقتصادی همواره مورد توجه محققان جهت مدل‌سازی و پیش‌بینی روند قیمتی و نوسانات آن بوده است. مدل‌های خطی و غیر خطی بسیاری ارائه و با استفاده از داده‌های آماری موجود تلاش شده است مدل‌هایی که خطای پیش‌بینی کم‌تری دارند انتخاب شوند.

اما آیا داده‌های قیمت نفت که در پیش‌بینی‌ها استفاده شده‌اند شفاف و بدون نویز هستند؟ در این مقاله، این فرضیه که آیا کاهش نویز از داده‌های نفتی منجر به پیش‌بینی مناسب‌تری از این قیمت می‌شود یا خیر مورد بررسی قرار گرفته است. به همین منظور، روشی ترکیبی از تبدیل موجک و شبکه عصبی مصنوعی برای پیش‌بینی بهای نفت خام ارائه شده است. در این مدل ابتدا داده‌های اولیه توسط تبدیل موجک گسسته (DWT)^۱ هموارسازی^۲ می‌شوند و سپس با داده‌های هموارسازی شده، توسط شبکه عصبی الگوسازی و پیش‌بینی انجام می‌گیرد. برای بررسی کارایی این روش، مدل حاضر با شبکه عصبی با ورودی‌های هموارسازی نشده مقایسه شده است. در ادامه مقاله، بخش دوم، مروری بر پیشینه تحقیقات انجام گرفته، دارد. بخش‌های سوم و چهارم، به بیان نظری تبدیل موجک و شبکه عصبی می‌پردازند. بخش پنجم، شامل نتایج و بخش ششم که در برگزیده نتیجه‌گیری است، پایان بخش مقاله خواهد بود.

1 - Discrete Wavelet Transformation.

2- Smooth.

۲- پیشینه تحقیق

اگر چه تحقیقات و مطالعات بسیاری در حوزه انرژی و نفت انجام گرفته، اما در این بخش فقط مقالاتی که به تبیین و پیش‌بینی قیمت نفت پرداخته‌اند، بررسی می‌شوند. گروهی از تحقیقات به مطالعه بی‌ثباتی^۱، یا به طور کلی به بررسی نوسانات قیمت نفت پرداخته‌اند تا از این طریق بتوانند بی‌ثباتی قیمت نفت در آینده را پیش‌بینی کنند. از آن جمله می‌توان به مطالعه لوئیس^۲ (۱۹۹۳) و استفاده وی از مدل $GARCH(1,1)$ ^۳ برای پیش‌بینی بی‌ثباتی قیمت نفت خام و یا به تحقیق دافی و گری^۴ (۱۹۹۴) و استفاده آن‌ها از مدل‌های $EGARCH(1,1)$ و $GARCH(1,1)$ برای پیش‌بینی بی‌ثباتی نفت حرراتی اشاره کرد. ابریشمی و همکاران (۱۳۸۶) نیز با استفاده از مدل‌های اتورگرسیو ناهمسانی شرطی (ARCH)^۵، به پیش‌بینی بی‌ثباتی قیمت نفت پرداختند، آن‌ها نتیجه گرفتند که مدل‌های $TGARCH$ و $GARCH$ ، عملکرد مناسب‌تری نسبت به سایر مدل‌ها دارند. از دیگر محققانی که در این زمینه به بررسی قیمت نفت پرداختند، می‌توان به سدروسکی^۶ (۲۰۰۶) اشاره کرد. وی نیز با استفاده از مدل‌های خانواده $GARCH$ ، از جمله $TGARCH$ و $BIGARCH$ ، به پیش‌بینی بی‌ثباتی قیمت آتی نفت خام پرداخت.

گروه دوم از مطالعات انجام شده برای پیش‌بینی قیمت نفت، بر روی مکانیسم عرضه و تقاضای این محصول متمرکز شده‌اند، که از آن جمله می‌توان به کارهای هگن^۷ (۱۹۹۴) و استیونز^۸ (۱۹۹۵)، اشاره کرد. هم‌چنین دیز و همکاران^۹ (۲۰۰۷)، با به‌کارگیری توابع رفتاری و متغیرهای فعالیت اقتصادی به پیش‌بینی تقاضای نفت پرداختند. گروه سوم تحقیقات ارائه شده برای پیش‌بینی بهای نفت خام، آن دسته از مدل‌ها هستند که برای لحاظ کردن پیچیدگی‌های بازار نفت، از الگوهای غیر خطی و ترکیبی

1 -Volatility.

2 -Lewis.

3 - Generalized ARCH.

4 -Duffie and Gray.

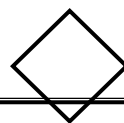
5 - Autoregressive Conditional Heteroskedasticity.

6 -Sadorsky.

7 -Hagen.

8 -Stevens.

9 -Dees et al.



استفاده کرده‌اند. در این راستا شمبارا و روسیتر^۱ (۲۰۰۵)، با استفاده از شبکه عصبی مصنوعی و میانگین متحرک‌های متناوب، به پیش‌بینی قیمت نفت خام در بازارهای آتی پرداختند، هم‌چنین وانگ و همکاران^۲ (۲۰۰۵)، قیمت نفت خام را بر اساس ترکیبی از مدل‌های خطی و غیر خطی، که خود مدل TEI@I نامیدند، پیش‌بینی و ذکر کردند که این مدل بر پیش‌بینی با یک شبکه عصبی به تنهایی برتری دارد. یوسفی و همکاران (۲۰۰۵)، از تبدیل موجک استفاده کردند و بهای نفت خام را در ابعاد زمانی مختلف پیش‌بینی نمودند. مشیری و همکاران (۲۰۰۶)، با استفاده از شبکه عصبی مصنوعی به پیش‌بینی قیمت‌های آتی نفت پرداختند. امین ناصری و قراچه (۲۰۰۷) نیز مدلی با استفاده از شبکه عصبی مصنوعی برای پیش‌بینی بهای نفت خام ماهانه ارائه دادند. هم‌چنین باوو و همکاران^۳ (۲۰۰۷)، به بررسی قیمت نفت با اتکا بر مدل ترکیبی (DWS-LSSVM)^۴ پرداختند. یو و همکاران^۵ (۲۰۰۷)، از شبکه عصبی چند مقیاسی مبتنی بر EMD^۶ استفاده کردند. الکساندر و لوانیز^۷ (۲۰۰۸)، به پیش‌بینی قیمت نفت خام با استفاده از شبکه عصبی موجک پرداختند. مهر آرا و همکاران (۲۰۰۸)، عایدی حاصل از پیش‌بینی در بازارهای آتی نفت را با روش تلفیقی شبکه عصبی GMDH^۸ و الگوریتم ژنتیک بررسی کردند. نتایج نشان داد که عایدی حاصل از پیش‌بینی روش تلفیقی مذکور، در دوره‌های مختلف زمانی نسبت به مدل‌های سنتی و خطی به مراتب بیشتر است. ابریشمی و همکاران (۲۰۰۸)، در تحقیقی از شبکه عصبی GMDH مبتنی بر الگوریتم ژنتیک برای پیش‌بینی قیمت بنزین با دو روش قیاسی و قواعد تحلیل تکنیکی، استفاده کردند. متغیرهای ورودی در روش قیاسی، شامل تمامی عوامل مؤثر (درون و برون سیستمی) بر قیمت بنزین و در روش تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه مدت و بلند مدت بود. نتایج نشان از دقت بیش از ۹۶٪ پیش‌بینی و پایداری روش قیاسی و بیش از ۹۹٪ تحلیل تکنیکی داشت. هم‌چنین در مقایسه معیارهای خطا، دقت پیش‌بینی‌های شبکه عصبی به طور

1 -Shambora & Rossiter.

2 -Wang et al.

3 -Bao et al.

4 - Least Squares Support Vector Machines.

5 -Yu et al.

6 - Empirical Mode Decomposition.

7 -Alexandridis & Livanis.

8 - Group Method of Data Handling.

معنی‌داری از الگوی رگرسیونی بهتر بود. براساس تحقیقات ذکر شده، می‌توان گفت که مدل‌های غیرخطی و ترکیبی، به ویژه با محوریت شبکه‌های عصبی، از آن‌جایی که عوامل بیش‌تری را در الگو سازی لحاظ می‌کنند، توانایی بالاتر و دقت بیش‌تری در پیش‌بینی قیمت نفت نسبت به مدل‌های رقیب دارند.

۳- تبدیل موجک

نشان داده شده که با منتقل کردن یک سری زمانی به سایر فضاها^۱، خواصی از آن سری زمانی دیده می‌شود که در فضای زمان، امکان رؤیت و بررسی آن‌ها نبوده است. در نتیجه مطالعه، یک سری زمانی در فضاها^۲ غیر از زمان، امکان بررسی بهتر و شفاف‌تری از سری زمانی را فراهم می‌کند. به عنوان مثال یک سری زمانی پیچیده، با استفاده از تبدیل فوریه^۳ می‌تواند به مجموعه‌ای از توابع سینوس با فرکانس‌های مختلف مختلف تبدیل شود و یا با استفاده از تبدیل موجک، ابعاد فرکانسی یک سری زمانی در زمان‌های متفاوت و با نمایش‌های متفاوت^۴ بررسی شود. این خاصیت موجک شد گردید تا رمزی^۴ (۱۹۹۹ و ۲۰۰۲)، این تبدیل را ابزاری مناسب برای بررسی تحلیل‌های اقتصادی عنوان کند. درذیل تئوری تبدیل موجک بیان می‌شود.

۱-۳- تئوری تبدیل موجک

تبدیل موجک با استفاده از توابع پایه‌ای^۵، 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 دارای انرژی محدودند^۶. این خاصیت موجک‌ها سبب می‌شود که این تبدیل، توانایی بررسی سری‌های نامان و زودگذر را داشته باشد.

1 -Domain.


2 -Fourier .

3 -Resolution.

4 -Ramsey.

5- Basis function.

6 -Finite Energy.




در فضای موجک، تابع پایه‌ای، موجک مادر^۱ نامیده می‌شود و مابقی توابع پایه ای از بسط و گسترش^۲ موجک مادر تولید می‌شوند. شکل (۱)، نمونه‌ای از بسط و گسترش موجک مادر هار^۳ است. برای یک سری زمانی پیوسته^۴، باید توابع پایه‌ای پیوسته، همانند موجک کلاه مکزیکی^۵ و مورلت^۶ (شکل ۲)، را استفاده کرد. بر اساس تعریف جن جن کی و همکاران^۷ (۲۰۰۱)، تبدیل پیوسته^۸ موجک عبارت است از:

$$W(u,s) = \int_{-\infty}^{\infty} x(t)\Psi_{u,s}(t)dt \quad (1)$$

و موجک مادر پیوسته $\Psi_{u,s}$ به صورت زیر تعریف می‌شود:

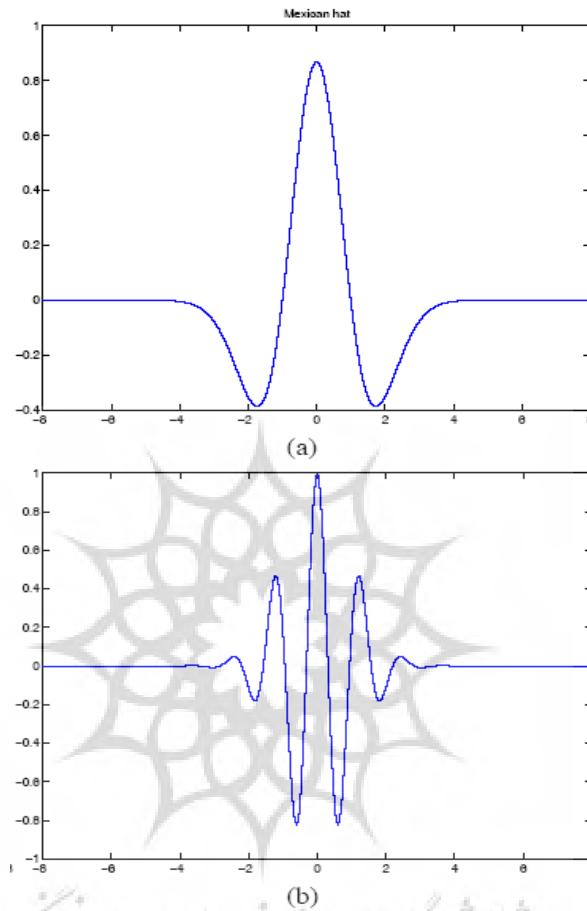
$$\Psi_{u,s} = \frac{1}{\sqrt{s}} \Psi\left(\frac{t-u}{s}\right) \quad (2)$$



شکل ۱- بسط و گسترش موجک مادر هار

منبع: سلسنیک^۸، ۲۰۰۵

- 1 -Mother Wavelet.
- 2 - Translation and Dilation.
- 3 -Haar.
- 4 -Continues time series.
- 5 -Mexican Hat.
- 6 -Morlet.
- 7 -Gencay.
- 8 - Selesnick.




شکل ۲- موجک‌های مورلت و کلاه مکزیکی - نمونه‌های موجک مادر پیوسته

منبع: نگارنده

در حالی که $\Psi_{u,s}$ تابعی از دو متغیر پیوسته s و u می‌باشد، s پارامتر اندازه^۱ موجک و u معرف مکان^۲ موجک است. با تغییر این متغیرها، تبدیل موجک توانایی تجزیه^۱ یک سری زمانی را در مقیاس و نمایش زمانی متفاوت به دست می‌آورد. در حالی که سری زمانی گسسته باشند، باید از موجک گسسته^۲ مادر، از جمله

1- Dilation(size).

2- Location.




هارودبیشز^۱ (شکل ۳) استفاده کرد. به طور کلی موجک گسسته مادر به صورت زیر است:

$$\Psi_{j,k} = 2^{j/2} \Psi(2^j - k) \quad j, k \in \mathbb{Z} \quad (3)$$

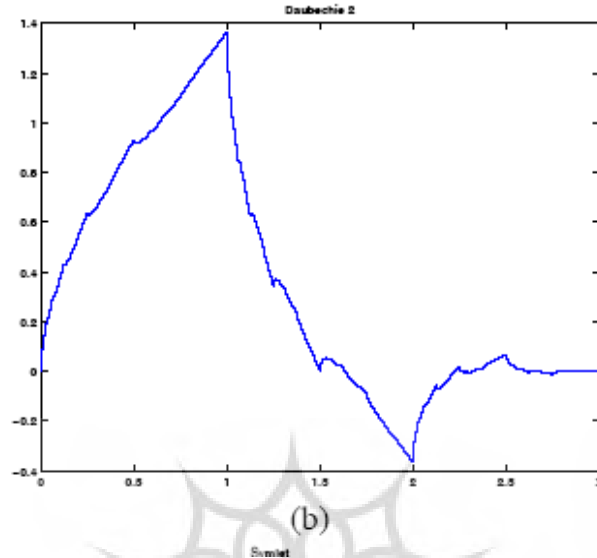
به طوری که k متغیر مکان موجک و j متغیر اندازه موجک است. برای مثال زمانی که j افزایش می یابد، اندازه موجک کوچک می شود، در حالی که نمایش زمانی افزایش می یابد. به طور کلی ضرایب تبدیل موجک گسسته $d_{j,k}$ ، از ضرب داخلی^۲ سری زمانی $x(t)$ در موجک مادر $\Psi_{j,k}$ ، به صورت زیر حاصل می شود:

$$d_{j,k} = \langle x(t), \Psi_{j,k}(t) \rangle = \int x(t) \Psi_{j,k}(t) dt \quad (4)$$



تا این مرحله صحبت از تبدیل یک سری زمانی به فضای موجک بوده است. از دیگر قابلیت های این تبدیل، تجزیه یک سری زمانی در مقیاس های نمایشی (زمان و مقیاس) مختلف می باشد. با اتکا بر تبدیل موجک، ملات^۳ (۱۹۹۸)، نظریه بررسی چند نمایشی^۴ یک سری زمانی را بیان کرد. براساس این نظریه، یک سری زمانی می تواند به دو بخش

1 -Daubechies.
2 -Inner Product.
3- Mallat.
4- Multiresolution Analysis.



شکل ۳- موجک هار و دبیشز - نمونه‌های موجک مادر گسسته

منبع : نگارنده


تقریبات^۱ و جزئیات^۲ تجزیه شود. در این حالت علاوه بر موجک مادر اصلی، یک تابع پایه، دیگر که توانایی جذب تقریبات را داشته باشد نیز نیاز است. این تابع که تابع مقیاس گر^۳ نام دارد، به صورت زیر تعریف می‌گردد.

$$\Phi_{j,k} = \tau^{j/2} \Phi(\tau^j - k) \quad j, k \in Z \quad (5)$$

در نتیجه هر تابع قابل انتگرال‌گیری مربع $(g(t) \in L^2(\mathbb{R}))$ می‌تواند با به‌کارگیری موجک مادر و مقیاس گر به صورت زیر نشان داده می‌شود.

$$g(t) = \sum c_{j \cdot}(k) \Phi_{c_{j \cdot}, k}(t) + \sum_k \sum_{j=j_0}^{\infty} c_{j \cdot}(k) \Psi_{c_{j \cdot}, k}(t) \quad (6)$$

-
- 1- Approximation.
 - 2- Details.
 - 3- Scaling Function.



معرف بخش تقریبات یا به بیان دیگر جز هموارشده $\sum c_{j_0}(k)\Phi_{c_{j_0},k}(t)$ سری زمانی و عبارت $\sum_{k=j_0}^{\infty} c_{j_0}(k)\Psi_{c_{j_0},k}(t)$ بیان گر جزئیات یا نویز موجود در سری زمانی می باشد.

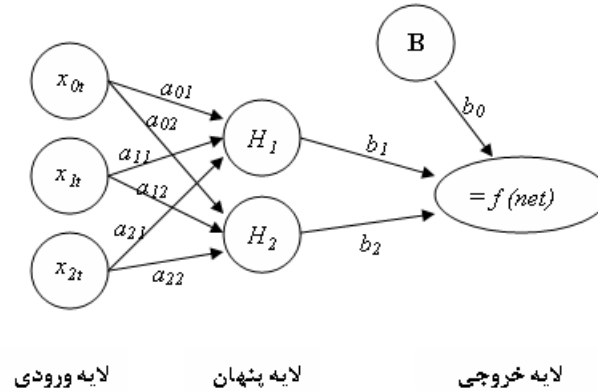
۴- شبکه عصبی مصنوعی

شبکه های عصبی یکی از متداول ترین فنون داده کاوی در طبقه بندی و پیشگویی در حوزه مالی بوده و می تواند برای پیش گویی هر سری زمانی مالی استفاده شود. یکی از مزایای شبکه های عصبی، کاربرد وسیع آن ها در زمینه های مختلف مسائل مالی بوده و ابزارهایی که از شبکه عصبی حمایت می کنند، تحت هر محیطی یافت می شوند. بازنمایی مختلف داده ها در شبکه های عصبی می تواند نتایج مختلفی را تولید نماید (جانگ^۱، ۱۹۹۵). بنابراین تنظیم داده ها نقش مهمی در استفاده از آن ها دارد (کاتسورلیس^۲، ۱۹۹۸).

شبکه عصبی عبارت از یک سیستم ورودی - خروجی است که پردازش اطلاعات توسط لایه های پنهان انجام می گیرد. بنابراین هر سیستم ورودی - خروجی با سازه شبکه عصبی دارای اجزای زیر است:

- ۱- لایه ورودی: شامل بردار متغیرهای مستقل
 - ۲- لایه های پنهان: شامل توابع عملگر، نرون های پردازش کننده داده های ورودی
 - ۳- لایه خروجی: شامل برآورد (پیش بینی) بردار متغیر هدف (وابسته)
- شکل ۳ سازه شبکه عصبی با یک لایه پنهان را نشان می دهد.

1 - Jang.
2 - Kutsurelis.



شکل ۳- شبکه عصبی با یک لایه پنهان

در ادبیات شبکه عصبی به جای اصطلاح تخمین ضرایب از اصطلاح یادگیری یا آموزش برای پیدا کردن ارزش‌های وزن‌های شبکه استفاده می‌شود. هدف کمینه کردن مجموع مربعات خطا یعنی اختلاف میان ارزش‌های خروجی واقعی و خروجی برآورد شده از شبکه عصبی می‌باشد.

بدین منظور داده‌ها را به دو مجموعه زیر تقسیم می‌کنند:


- ۱- آموزش (Train): الگوسازی و شبیه‌سازی (۷۰٪ داده‌ها را شامل می‌شود)
- ۲- آزمون (Test): پیش‌بینی (۳۰٪ داده‌ها را شامل می‌شود)

۲-۴- شبکه عصبی نوع چند لایه پیشرو^۱ *MLFF*

شبکه عصبی چند لایه با الگوریتم پیش‌خور یکی از معروف‌ترین شبکه‌های عصبی است که در بیش از نیمی از تحقیقات انجام گرفته در بازارهای مالی و اقتصاد استفاده شده است (سرینی واسان و همکاران^۲، ۲۰۰۲). این نوع شبکه عصبی از نرون‌هایی در چند لایه تشکیل شده است، که معمولاً با الگوریتم پیش‌خور به هم مرتبطند. در

1 - Multi Layer Feed Forward.

2 - Srinivasan et al.



بیشتر موارد، یک تابع سیگموئید^۱ به عنوان تابع انتقال به کار می‌رود (بیات، ۱۳۷۶).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

این تابع مشتق پیوسته دارد و اجازه می‌دهد قاعدهٔ پس انتشار استفاده شود و مشتق آن نیز به سادگی محاسبه می‌شود.

$$y' = y(1 - y) \quad (8)$$

شبکه‌های چند لایه روش‌های مختلفی را برای یادگیری استفاده می‌کنند، که مشهورترین آن الگوریتم پس انتشار^۲ BPA می‌باشد که الگوریتم فراگیر با سرپرست است و خطای سیستم را حداقل می‌کند (کامارتی و پیتنر^۳، ۱۹۹۹). در این فرآیند یادگیری، یک بردار وزن اولیه w_0 تعدیل می‌شود (کارتالوپولوس^۴، ۲۰۰۰):

$$w_i(k+1) = w_i(k) + \mu(T_i - O_i)f'(w_i x_i)x_i \quad (9)$$

w_i ماتریس وزن نرون i ام است، x_i ورودی نرون i ام است، O_i خروجی حقیقی نرون i ام، T_i خروجی هدف نرون i ام و μ پارامتر نرخ یادگیری است. مقادیر خروجی (O_i) با جواب صحیح مقایسه می‌شوند تا تابع خطای پیش تعریف شده^۵ محاسبه شود. شبکهٔ عصبی توسط معادلهٔ تعدیل اوزان، فرآیند یادگیری با هدف کاهش میانگین مربع خطا را که با معادلهٔ زیر تعریف می‌شود، می‌گذراند:

$$E = \frac{1}{2}(T_i - O_i)^2 = \frac{1}{2}[T_i - f(w_i x_i)]^2 \quad (10)$$

این الگوریتم وزن‌های هر ارتباط را با هدف کاهش تابع خطا تعدیل می‌کند. بعد از تکرار این فرآیند، آموزش شبکهٔ عصبی به نقطه‌ای منتهی می‌شود که خطای محاسبات حداقل است. برای تعدیل مناسب وزن‌ها یک روش بهینه سازی غیرخطی به کار برده می‌شود که کاهش گرادیان^۶ نامیده می‌شود (لیپمن^۷، ۱۹۸۷).

-
- 1 - Sigmoid Function.
 - 2 - Back-Propagation Algorithm.
 - 3 - Kamarthi and Pittner.
 - 4 - Kartalopoulos.
 - 5 - Predefined Error-Function.
 - 6 - Gradient Descent.
 - 7 - Lippmann.


الگوریتم فراگیری پس انتشار کاهش گرادیان، سعی می‌کند تا مربع خطای بین خروجی‌های شبکه و تابع هدف مینیمم شود. روش گرادیان سعی می‌کند تا با مینیمم کردن خطا، به نتیجه مناسبی دست یابد. اما تضمینی برای این که این الگوریتم به مینیمم مطلق برسد، وجود ندارد.

۵- نتایج

بر اساس این فرضیه که آیا کاهش نویز و هموار سازی داده‌ها می‌تواند پیش‌بینی ما را از قیمت نفت بهبود بخشد، در این تحقیق از مدل ترکیبی موجک و شبکه عصبی استفاده شده است. این فرضیه برای داده‌های روزانه ۲۰۰۰/۱/۴ الی ۲۰۰۴/۹/۲ نفت خام نیویورک و نفت خام خلیج مکزیک، آزمون شده است. در این دوره قیمت نفت خام کم‌تر از ۱۰۰ می‌باشد و بعد از این دوره قیمت نفت شاهد نوسانات غیرقابل انتظاری بوده است و قیمت، نوسانات صعودی بالای ۱۰۰ را داشته است. به همین منظور برای آزمون مدل ترکیبی خود برای جلوگیری از اثرگذاری نوسانات غیرمعمول قیمت نفت خام بر نتایج، دوره ذکر شده انتخاب شده است. با توجه به دو سطر ابتدایی جدول (۱)، می‌توان مشاهده کرد که قیمت نفت خام نیویورک، میانگین ۸۰/۸۱ و انحراف معیار ۱۳/۰۴ دارد، در حالی که میانگین قیمت نفت خام خلیج مکزیک ۷۹/۷۴ است.

در تبدیل موجک، از موجک مادر دابیشز به منظور تجزیه استفاده شده است و داده‌ها تا مرحله ۴ تجزیه شده‌اند. سپس ضرایب جزئیات در مرحله ۴ حذف شده (ضرایب جزئیات بیانگر نویز داخل داده‌ها هستند) و با استفاده از ضرایب تقریبات، سری زمانی بازسازی می‌شود و سری زمانی هموار سازی شده به دست می‌آید. هنگام استفاده از تبدیل موجک گسسته به این نکته باید توجه داشت که سری زمانی، اندازه دوتایی^۱ داشته باشد. اما به طور حتم این شرط همیشه برقرار نیست. یک راه حل معمول برای حل این مسئله این است که می‌توان اندازه سری زمانی را تا جایی که به اندازه دوتایی برسد افزایش داد^۲. برای این کار اصولاً از عدد صفر^۳، میانگین سری زمانی، تکرار عدد آخر سری زمانی و یا تکرار دوره‌های^۴ خود سری زمانی، استفاده می‌شود. در این تحقیق از روش تکرار دوره‌های خود سری زمانی استفاده شده است.

1- Dyadic Length.
2- Padding Process.
3- Zero Padding.
4 -Periodic.



جدول ۱- مشخصات آماری قیمت نفت خام برای دوره ۲۰۰۴/۹/۲ الی ۲۰۰۰/۱/۴

کشیدگی ^۱	چولگی ^۲	انحراف معیار	میانگین	قیمت نفت خام
-۰/۱۷	-۰/۴۲	۱۳/۰۳	۸۰/۸۱	نیویورک
۰/۸	-۰/۴۴	۱۳/۰۴	۷۹/۷۴	خلیج مکزیک
-۰/۱۲	-۰/۵۳	۱۲/۵۷	۸۰/۸۱	نیویورک (هموارسازی شده)
۰/۱۵	-۰/۵۶	۱۲/۴۸	۷۹/۷۴	خلیج مکزیک (هموارسازی شده)

مشخصات آماری قیمت‌های هموارسازی شده در دو ردیف انتهایی جدول (۱) ذکر شده‌اند. همان طور که ملاحظه می‌شود، میانگین داده‌ها، تفاوتی نسبت به زمانی که هموارسازی انجام نگرفته است، ندارد، در حالی که انحراف معیارها کاهش یافته‌اند، که این امر دلالت بر آن دارد که اطلاعاتی به غیر از نویز از داده‌ها خارج نشده است. در مرحله دوم روش ترکیبی، ورودی‌ها شامل میانگین متحرک‌های ۵ و ۵۰ روزه هموارسازی نشده، میانگین متحرک‌های ۵ و ۵۰ روزه هموارسازی شده و تفاضل میانگین متحرک ۵ و ۵۰ روزه در هر دو حالت هموار و غیر هموارسازی شده هستند. نمونه‌ای به اندازه ۳۰۰ روز مورد پیش‌بینی قرار گرفته است. در مدل شبکه عصبی تنها، ورودی‌ها شامل داده‌های غیر هموار هستند. برای ارزیابی مدل ترکیبی با مدل ساده شبکه عصبی، از معیار ریشه مجموع مربعات خطای پیش‌بینی (RMSE)^۳ استفاده شده است.

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

\hat{y}_t پیش‌بینی قیمت نفت خام در دوره t و y_t قیمت واقعی نفت خام در دوره t است.

1 -Kurtosis.

2 -Skewness.

3 - Residual Mean Square Error.

جدول (۲)، مقادیر این معیار را برای نفت خام نیویورک و خلیج مکزیک، گزارش می‌دهد. درحالی‌که نفت خام نیویورک مورد پیش‌بینی بوده، RMSE شبکه عصبی به تنهایی معادل ۳/۷۸ و روش ترکیبی تبدیل موجک و شبکه برابر ۳/۳۳ است، که نشان می‌دهد خطای پیش‌بینی با کم کردن نویز از داده‌ها، ۱۳٪ کاهش یافته است.

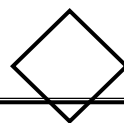
جدول ۲- نتایج RMSE برای الگوها و داده‌های مختلف

الگو	نفت خام نیویورک	نفت خام خلیج مکزیک
موجک + شبکه عصبی	۳/۳۳	۳/۷
شبکه عصبی	۳/۷۸	۴/۱

هم‌چنین باتوجه به جدول (۲)، می‌توان مشاهده کرد که معیار RMSE برای پیش‌بینی قیمت نفت خلیج مکزیک از ۴/۱ به ۳/۷ در شبکه عصبی تنها، نسبت به روش ترکیبی کاهش داشته و نشان می‌دهد استفاده از تبدیل موجک و هموارسازی داده‌ها منجر به کاهش ۱۱ درصدی خطای پیش‌بینی می‌شود.

۶- نتیجه‌گیری

از آنجایی که نفت خام یک عنصر استراتژیک در بسیاری از صنایع و بازارها می‌باشد، پیش‌بینی قیمت آن و شناسایی روند حرکت آن همواره مورد توجه محافل تجاری و علمی بوده است. تاکنون مدل‌های متفاوت و گوناگونی ارائه شده و تلاش همه مدل‌ها بر آن بوده است که پیش‌بینی با خطای کم‌تر را داشته باشند. در این مقاله با استفاده از روش ترکیبی تبدیل موجک و شبکه عصبی تلاش شده است تا الگویی ارائه گردد که پیش‌بینی مناسب‌تری از قیمت نفت خام داشته باشد. در این مدل از ترکیب خاصیت هموارسازی تبدیل موجک استفاده و سطح نویز داده‌های نفتی کاهش داده شد و ورودی‌های شبکه عصبی بر اساس این داده‌های هموارسازی شده طراحی گردید. نتایج حاکی از آن است که معیار خطای پیش‌بینی (RMSE) در روش ترکیبی تبدیل موجک و شبکه عصبی، کاهش چشمگیری نسبت به حالت شبکه عصبی تنها دارد. به طور کلی می‌توان بیان نمود که وجود نویز در داده‌ها امکان این را دارد که منجر به



پیش‌بینی ناصحیح از قیمت نفت خام گردد و تبدیل موجک می‌تواند به‌عنوان یک ابزار مناسب برای کاهش این ناخالصی در داده‌ها استفاده گردد.

فهرست منابع

ابریشمی، حمید، آریانا، یاسمین، مهرآرا، محسن، ۱۳۸۶، ارزیابی عملکرد مدل‌های پیش‌بینی بی‌ثباتی قیمت نفت، مجله تحقیقات اقتصادی، شماره ۷۸.

ابریشمی، معینی، مهرآرا، احاراری و سلیمانی کیا، مدل‌سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه عصبی GMDH مبتنی بر الگوریتم ژنتیک، فصلنامه پژوهش‌های اقتصادی ایران، دانشکده اقتصاد دانشگاه علامه طباطبائی، شماره ۳۶، پائیز ۱۳۸۷.

بیات، لیلا، تسریع الگوریتم پس انتشار خطا در شبکه‌های عصبی چند لایه الگوریتم تانژانت موازی پویا، پایان‌نامه (کارشناسی ارشد)، دانشگاه علم و صنعت ایران، ۱۳۷۶.

Amin-Naseri, M, E.A. Gharacheh E. 2007. A hybrid artificial intelligence approach to monthly forecasting oil price time series. Proceedings of EANN.

Alexandridis, A. Livanis, E. 2008. Forecasting Crude Oil Prices Using Wavelet Neural Networks. users.uom.gr/~aalex/files/Download/FSDET%202008%20.pdf

Bao Yejing, Zhang Xun, Yu Lean, Wang Shouyang. 2007. Crude Oil Price Prediction Based On Multi-scale Decompositio. Springer-Verlag Berlin Heidelberg.


Day T.E. and C.M. Lewis. 1993. Forecasting Futures Markets Volatility, the Journal of Derivatives, and winter 1993, pp. 33-50.

Dees, P. Karadeloglou, R.K. Kaufmann and M. Sanchez 2007. Modeling the world oil market: Assessment of a quarterly econometric model. Energy Policy vol. 35, pp. 178-191.

Duffie D. and S. Gray. 1995. Volatility in Energy Prices, Managing Energy Price Risk, Risk Publications, London, pp. 39-55.

Egeli, B., Ozturan, M., Badur, B. 2002. Stock Market Prediction Using Artificial Neural Networks, Department of Management Information Systems, Bogazici University, Istanbul, Turkey.

- Genay, R., F. Seluk, and B. Whitcher, 2001, *An Introduction to Wavelets and Other Filtering Methods in Finance and Economics*, Academic Press.
- Hagen, R., How is the international price of a particular crude determined? *OPEC Review*, 1994, 18(1): 145–158.
- Huntington, H. G. 1994, Oil price forecasting in the 1980s: what went wrong? *The Energy Journal*, 15(2), 1–22.
- Kutsurelis, Jason E. *Forecasting Financial Markets Using Neural Networks: An Analysis of Methods and Accuracy*, Msc Thesis, US Naval Academy, 1998.
- Kamarathi, S.V. and Pittner, S.; Accelerating neural network training using weight extrapolation; *Neural Network*, 1999, 12, 1285-1299.
- Kartalopoulos, S.V.; *Understanding Neural Networks and Fuzzy Logic-Basic Concepts and Applications*; Prentice Hall, New-Delhi, 2000.
- Lippmann, R.P.; An introduction to computing with neural nets; *IEEE Mag.* 3 (4), P.P: 4-22, 1987.
- Mallat, S., 1989, A Theory for Multiresolution Signal Decomposition: The Wavelet Representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11, 674–693.
- Mehrara M, Moeini A, Ahrari M, Erfanifard A. Investigating the efficiency in oil futures market based on GMDH approach. *Journal of Expert Systems with Applications* 2008; Elsevier Science.
- Mirmirani S. and Li, H.C.; Gold Price, Neural Networks and Genetic Algorithm; *Computational Economics* 23: 193–200, 2004.
- Moshiri S, Foroutan F, 2006, Forecasting nonlinear Crude Oil Prices, the energy journal, Volume 27, No.4, pages 81-95.
- Priestley M. B.; *Non-linear and non-stationary time series analysis*; Academic Press, 1988.
- Ramsey, J. B., 1999, The contribution of wavelets to the analysis of economic and financial data, *Philosophical Transactions: Mathematical, Physical and Engineering Sciences*, 357, Royal Society of London Philosophical Transactions Series A.
- Ramsey, J. B., 2002, “Wavelets in Economics and Finance: Past and Future” *Studies in Nonlinear Dynamics and Econometrics*, 6, <http://www.bepress.com/snnde/vol6/iss3/art1>.
- Sadorsky, P. 2006. Modeling and forecasting petroleum futures volatility. *Energy Economics* vol. 28, pp. 467-488.



Selesnick, I., 2005, “Digital Signal Processing” <http://taco.poly.edu/selesi/>

Shambora and Rossiter, 2007, Are there exploitable inefficiencies in the futures market for oil? Journal of Energy Economics, Volume: 29 Pages: 18-27.

Srinivasan, Ravichandran, Chan, Vidhya, Ramakirishnan, Krishnan, Exponentiated back propagation algorithm for multilayer feed forward neural network, Neural Information Processing, ICONIP apos; 02. Proceedings of the 9th International Conference on, Volume 1, Issue 18-22, Page(s): 327 – 331, Nov 2002.

Stevens. P. 1995, The determination of oil prices 1945–1995, Energy Policy, 23(10): 861–870.

Wang S, Yu L, Lai K. Crude Oil Price Forecasting with TEI@I Methodology, Journal of Systems Science and Complexity, Volume 18, No. 2, 2005.

Yu L, Lai K.K, Wang S, He K, Oil Price Forecasting with an EMD –BASED Multistage Neural Network Learning Paradigm, Lecture Notes in computer science, Volume 4489, 2007, pages 925-932.

Yousefi, S. Weinreich, I. Reinarz, D., 2005, Wavelet-based prediction of oil prices. Chaos, Solitons and Fractals 25, pp. 265-275.