

ارزیابی عملکرد الگوهای شبکه‌ی عصبی و خودرگرسیون میانگین متحرک در پیش‌بینی قیمت نفت خام ایران

سید ابراهیم دشتی رحمت آبادی

دانشجوی دکتری و عضو هیئت علمی دانشگاه آزاد اسلامی جهرم

حمید محمدی*

استادیار گروه اقتصاد کشاورزی دانشگاه زابل hamidmohammadi1378@gmail.com

زکریا فرج‌زاده

دانشجوی دکتری دانشگاه شیراز

تاریخ دریافت: 89/3/4 تاریخ پذیرش: 89/8/18

چکیده

این مطالعه با هدف معرفی الگوهای مطلوب پیش‌بینی برای قیمت نفت خام ایران انجام شده است. داده‌های مورد استفاده به صورت هفتگی و شامل دوره‌ی 1997-2010 می‌باشد و پیش‌بینی‌ها برای 10، 20 و 30 درصد داده‌های یاد شده انجام گرفته است. الگوهای مورد استفاده برای پیش‌بینی، شامل 4 الگوی شبکه‌ی عصبی و یک الگوی رگرسیونی (خودرگرسیون میانگین متحرک) بوده است. شبکه‌های منتخب شامل شبکه‌ی پیشخور پس انتشار، شبکه‌ی آبخاری پس انتشار، شبکه‌ی المان پس انتشار و شبکه‌ی رگرسیون تعمیم یافته می‌باشد. هم‌چنین توابع آموزش مورد استفاده در پیش‌بینی شامل توابع لونیبرگ-مارکوات و شبه‌ی نیوتنی است. یافته‌های به دست آمده نشان می‌دهد برای پیش‌بینی 10 درصد از داده‌های قیمت نفت خام، الگوهای شبکه‌ی رگرسیون تعمیم یافته و شبکه‌ی آبخاری پس انتشار با تابع آموزش شبه‌ی نیوتنی، به ترتیب با خطایی کم‌تر از 1 و کم‌تر از 2 درصد دارای بهترین عملکرد هستند. برای پیش‌بینی 20 درصد داده‌های قیمت نفت خام ایران، شبکه‌ی پیشخور پس انتشار و شبکه‌ی المان پس انتشار با تابع آموزش لونیبرگ-مارکوات، دارای عملکرد بهتر می‌باشند. در مورد 30 درصد از داده‌ها نیز شبکه‌ی پیشخور پس انتشار مطلوب‌تر ارزیابی شده است. هم‌چنین نتایج نشان می‌دهد به طور نسبی با افزایش درصد داده‌های مورد استفاده در پیش‌بینی، دقت پیش‌بینی‌ها به‌ویژه با افزایش از 10 درصد به 20 درصد رو به افول می‌رود. دقت پیش‌بینی خودرگرسیون میانگین متحرک نیز پایین‌تر از الگوهای شبکه‌ی عصبی ارزیابی می‌شود.

طبقه‌بندی JEL: C45, C53, Q49

کلید واژه: قیمت، پیش‌بینی، نفت خام ایران، شبکه‌ی عصبی مصنوعی، خودرگرسیون میانگین متحرک.

* نویسنده‌ی مسئول

1- مقدمه

انرژی، نهاده‌ای استراتژیک در فرایند تولید است که تغییرات قیمت آن بر اقتصاد تمام جهان تأثیرگذار می‌باشد. در میان کشورهای عرضه‌کننده همانند ایران، اثر آن بر درآمدهای ارزی بسیار حایز اهمیت است. در دوره‌ی 69-1338، به جز در سال 1359، همواره بیش از 80 درصد از درآمد ارزی ایران از محل فروش نفت حاصل شده است. در دوره‌ی 82-1370 نیز این رقم تنها تا کم‌تر از 69 درصد کاهش یافته است (بانک مرکزی ایران، 1386). اتکای بالا به درآمد ارزی نفت، افزون بر پدیده‌ی بیماری هلندی، موجب آسیب‌پذیری از نوسانات ناشی از درآمدهای ارزی نیز می‌شود. این نوسان از طریق انتقال نوسان به فعالیت‌های اقتصادی می‌تواند هزینه‌هایی را به اقتصاد تحمیل کند. قیمت نفت‌خام ایران همانند قیمت جهانی نفت‌خام همواره با نوسان بالا مواجه بوده است، به‌عنوان مثال در حالی که قیمت نفت‌خام ایران در جولای سال 2008 به بیش از 136 دلار در هر بشکه افزایش یافته بود، اما تنها کم‌تر از 6 ماه بعد از آن به کم‌تر از 40 دلار کاهش یافت (سازمان مدیریت اطلاعات انرژی ایالات متحده، 2010). چنین نوسان بزرگی افزون بر کاهش دسترسی به درآمد ارزی، موجب عدم اطمینان شدید می‌شود که ممکن است هزینه‌های آن بسیار بالا بوده و تا مدتی طولانی بر جای بماند. هرچند وجود نوسان در بازار نفت امری پذیرفته شده می‌باشد، اما بحث حایز اهمیت مدیریت و نحوه‌ی برخورد با چنین شرایطی است که می‌تواند به‌صورت اتخاذ سیاست‌های ارزی یا پولی و مالی در جهت کاهش اثرات نوسان ناشی از قیمت نفت باشد. در همین راستا تلاش در جهت شناخت بیش‌تر رفتار قیمت نفت‌خام نیز می‌تواند به‌عنوان یک ابزار مهم، به‌ویژه در کوتاه مدت مورد توجه سیاست‌گذاران قرار گیرد. این شناخت رفتار می‌تواند به‌صورت پیش‌بینی روند تغییرات آن‌ها در آینده باشد. امروزه ابزارهای مناسبی برای این منظور در دسترس هستند که می‌توانند پیش‌بینی‌های مطلوبی ارائه کنند.

در ادامه، در بخش 2، پیشینه‌ی تحقیق، بخش 3، روش شناسی تحقیق، بخش 4، یافته‌های تحقیق و بخش 5، نتیجه‌گیری و پیشنهادات، ارائه می‌گردد.

2- پیشینه‌ی تحقیق

استفاده از الگوهای جدید پیش‌بینی برای انواع حامل‌های انرژی و از جمله قیمت نفت‌خام نیز بیانگر اهمیت قابل ملاحظه‌ی پیش‌بینی قیمت انرژی است. در مورد

پیش‌بینی قیمت نفت خام به‌طور خاص استفاده از دو گروه از الگوها مشهود است. در برخی از آن‌ها تلاش شده است تا رفتار نوسانات قیمت نفت با استفاده از الگوهای رگرسیونی، شناسایی و از این طریق پیش‌بینی‌هایی ارائه شود. بررسی نوسانات قیمت جهانی نفت توسط ویکام¹ (1996)، مورانا² (2001)، لانزا و همکاران³ (2005) و کانگ و همکاران⁴ (2009) و هم‌چنین بررسی نوسانات قیمت نفت وست تگزاس اینترمدیت‌WTI⁵ توسط ابریشمی و همکاران (1386)، از جمله‌ی این مطالعات هستند. نکته‌ی حایز اهمیت در این مطالعات وجود ویژگی موسوم به اثر خودرگرسیون با واریانس ناهمسانی شرطی⁶ می‌باشد که امکان بیان رفتار نوسان قیمت نفت را فرآهم کرده است. هر چند وجود نوسان گسترده، امکان استفاده از چنین الگوی رگرسیونی را مقدور کرده است، اما پیشرفت‌های اخیر در زمینه‌ی مدل‌های پیش‌بینی، دقت پیش‌بینی‌ها را به‌طور جالب توجهی افزایش داده است. شبکه‌ی عصبی مصنوعی از جمله‌ی این روش‌ها است که به‌طور گسترده برای پیش‌بینی قیمت بسیاری از متغیرهای اقتصادی و از جمله قیمت انرژی مورد استفاده قرار گرفته است. پیش‌بینی قیمت نفت خام آمریکا (کبودان⁷، 2001)، پیش‌بینی قیمت نفت وست تگزاس اینترمدیت و برنت (یو و همکاران⁸، 2008)، پیش‌بینی قیمت جهانی نفت (فرجام نیا و همکاران، 1386)، پیش‌بینی قیمت نفت خام نیویورک و خلیج مکزیک (بهرادامهر، 1387)، پیش‌بینی قیمت نفت خام ایران (اصفهانیان، 1382؛ اصفهانیان و امین ناصری، 1387) و هم‌چنین پیش‌بینی قیمت بنزین بازار سنگاپور (ابریشمی و همکاران، 1387)، از جمله‌ی این موارد هستند. البته در برخی از آن‌ها روش شبکه‌ی عصبی با برخی از روش‌های رگرسیونی و به‌ویژه با روش خودرگرسیون میانگین متحرک مقایسه شده است. مطالعه‌ی یو و همکاران (2008)، فرجام نیا و همکاران (1386) و هم‌چنین شریف‌النبی (1378)، از جمله‌ی این مطالعات هستند که یافته‌های آن‌ها حاکی از برتری شبکه‌ی عصبی بر خودرگرسیون میانگین متحرک در پیش‌بینی است. به‌طور کلی می‌توان گفت استفاده از شبکه‌ی عصبی در پیش‌بینی قیمت حامل‌های انرژی و از جمله

1- Wickham.

2- Morana.

3- Lanza.

4- Kang et al.

5- West Texas Intermediate.

6- Autoregressive Conditional Heteroskedasticity.

7- Kaboudan.

8- Yu et al.

نفت، بیش‌تر مورد توجه بوده و دقت بالاتر آن نیز در مطالعات مقایسه‌ای مورد تأکید قرار گرفته است. با توجه به اهمیت قیمت نفت‌خام ایران در اقتصاد ایران، این مطالعه با هدف پیش‌بینی قیمت نفت‌خام ایران و یافتن الگوی مناسب برای پیش‌بینی انجام گرفته است. ویژگی متمایز مطالعه‌ی حاضر در مقایسه با مطالعات مرور شده این است که افزون بر استفاده از الگوهای مختلف شبکه‌ی عصبی که در بیش‌تر مطالعات تنها برخی از آن‌ها مورد استفاده قرار گرفته است، داده‌ها قبل از آموزش شبکه، مورد پردازش قرار گرفته‌اند. این پردازش شامل تصادفی کردن قیمت و تفکیک تغییرات به تغییرات مثبت و منفی می‌باشد. استفاده از قیمت نفت‌های تعیین‌کننده وست تگزاس اینترمدیت و برنت در آموزش شبکه، از دیگر ویژگی‌های بارز مطالعه‌ی حاضر است.

3- روش شناسی تحقیق

در این بخش روش شبکه‌های عصبی مصنوعی، الگوی خودرگرسیون میانگین متحرک و نحوه انتخاب بهترین مدل پیش‌بینی‌کننده، معرفی و تشریح می‌گردد.


3-1- شبکه‌های عصبی مصنوعی¹

امروزه به موازات مدل‌های متداول قبلی، روش‌های جدیدتری نیز برای پیش‌بینی ابداع شده است. این روش‌ها که به شبکه‌های عصبی مصنوعی موسومند، مدل ساده شده‌ای از سیستم عصبی مرکزی هستند و همانند مغز با پردازش روی داده‌های تجربی، قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. در حقیقت شبکه، با انجام محاسبات روی داده‌های عددی یا مثال‌ها، قوانین کلی را فرا می‌گیرد و به همین دلیل به آن سیستم هوشمند گفته می‌شود. یک شبکه‌ی عصبی از نرون‌های مصنوعی تشکیل شده است. نرون یا گره، کوچک‌ترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد (منهاج، 1377). هر یک از نرون‌ها، ورودی‌ها را دریافت و پس از پردازش روی آن‌ها، یک سیگنال خروجی تولید می‌کند، لذا هر نرون در شبکه به‌عنوان مرکز پردازش و توزیع اطلاعات عمل محسوب می‌شود و ورودی و خروجی مخصوص به خود را دارد (وو و لو²، 1995). شکل (1)، نمایش

1- Artificial Neural Networks.

2- Wu and Lu.

ساختار یک نرون تک ورودی می‌باشد، که در آن عددهای p و a ، به ترتیب ورودی و خروجی نرون هستند.




مأخذ: منهاج (1377)

نمودار 1- مدل نرون تک ورودی

میزان تأثیر p روی a به وسیله‌ی مقدار عدد w تعیین می‌شود. ورودی دیگر، مقدار ثابت b است که در جمله‌ی b ضرب شده و سپس با wp جمع می‌شود. این حاصل جمع ورودی خالص n ، برای تابع تبدیل یا فعال سازی (محرک) f ، است. بدین ترتیب خروجی نرون به صورت معادله‌ی (1) تعریف می‌شود:

$$a = f(wp + b) \quad (1)$$

پارامترهای w و b قابل تنظیم هستند و تابع محرک f نیز توسط طراح انتخاب می‌شود. پارامترهای w و b براساس انتخاب f و نوع الگوریتم یادگیری، تنظیم می‌شوند. در حقیقت یادگیری به این معنی است که w و b طوری تغییر کنند که رابطه‌ی ورودی و خروجی نرون با هدف خاصی مطابقت کند. به طور معمول یک نرون، بیش از یک ورودی دارد. در شکل (2)، مدل یک نرون با R ورودی نشان داده شده است.



مأخذ: منهاج (1377)

نمودار 2- مدل چند ورودی یک نرون

در شکل (2)، عددهای P_1 عناصر بردار ورودی هستند و با ماتریس وزن W و جمله ی اریب (b) ، ورودی خالص را به صورت رابطه‌ی (9) تشکیل می‌دهند:

$$n = \sum_{i=1}^R P_1 W_{1,i} + b = W\bar{p} + b \quad (2)$$

که در آن $\bar{p} = [P_1, P_2, \dots, P_R]^T$ و $W = [W_{1,1}, W_{1,2}, \dots, W_{1,R}]$ و در نهایت خروجی نرون به صورت رابطه‌ی (3) خواهد بود:

$$a = f(W\bar{p} + b) \quad (3)$$


معمولاً یک نرون حتی با تعداد ورودی‌های زیاد نیز به تنهایی برای حل مسائل کفایت نمی‌کند (منهاج، 1377)، بنابراین در بیش‌تر موارد از اجتماعی از چند نرون به عنوان یک لایه، استفاده می‌شود. شبکه‌های عصبی مصنوعی همانند شبکه‌های عصبی بیولوژیکی می‌توانند به روش‌های مختلف سازمان دهی شوند. بدین مفهوم که نرون‌ها می‌توانند از راه‌های متفاوت به هم متصل شوند و شبکه‌های عصبی با ساختارهای مختلفی تولید کنند. در حال حاضر انواع مختلفی از شبکه‌های عصبی وجود دارد که برخی از آن‌ها دارای کاربرد بیش‌تری هستند. بررسی مطالعات حاکی از تأکید بر استفاده از شبکه‌هایی مانند شبکه‌ی پیشخور پس انتشار و شبکه‌ی آبخاری پس انتشار است. به‌عنوان مثال کبودان (2001) و هم‌چنین یو و همکاران (2008)، شبکه‌ی پیشخور پس انتشار را پیشنهاد و مالیک و ناصرالدین¹ (2006)، شبکه‌ی آبخاری پس انتشار را مناسب ارزیابی کردند. شبکه‌ی پیشخور پس انتشار در مطالعه‌ی اصفهانیان (1382) و اصفهانیان و ناصری (1387) نیز مورد تأکید قرار گرفته است. در این مطالعه افزون بر شبکه‌های یاد شده، دو شبکه‌ی رگرسیون تعمیم یافته و شبکه‌ی المان پس انتشار نیز که در برخی از مطالعات همانند اصفهانیان و امین ناصری (1387) مورد توجه قرار گرفته بودند، استفاده شدند که در ادامه معرفی می‌شوند.

شبکه‌ی پیشخور پس انتشار²

در نمودار (3)، یک نمونه از شبکه‌ی پیشخور پس انتشار با دو لایه‌ی پنهان نشان داده شده است. در این شبکه هر نرون از لایه‌ها اطلاعات را از نرون‌های لایه‌ی ما قبل

1- Malik and Nasereddin.

2- Feed forward Back Propagation Network.



نمودار 3- ساختار شبکه‌ی پیشخور پس انتشار با دو لایه‌ی پنهان

دریافت و پس از پردازش آن را به نرون‌های لایه‌ی بعد می‌دهد و این فرایند به‌طور معکوس تکرارپذیر نیست. در شبکه‌ی زیر، X بردار داده‌های ورودی، Y بردار داده‌های خروجی و F تابع عملگر است که پردازش بر روی داده‌ها را انجام می‌دهد (ایلینا و همکاران¹، 2004).

شبکه‌ی المان پس انتشار²

شبکه‌ی المان نیز دارای ساختاری مشابه شبکه‌ی پیشخور پس انتشار است، اما از نظر نوع عملکرد با آن دارای تفاوت است. به این ترتیب که شبکه‌ی المان پس انتشار برخلاف شبکه‌ی پیشخور پس انتشار برگشتی است. در حقیقت این شبکه لایه‌ی داده‌های ورودی شامل دو قسمت است، قسمت اول داده‌های واقعی را شامل می‌شود و قسمت دوم، اطلاعاتی از پردازش داده‌ها توسط لایه‌ی پنهان را در خود حفظ می‌کند. به این ترتیب اطلاعات ایجاد شده توسط یک لایه‌ی پنهان دوباره توسط لایه‌ی ورودی مورد استفاده قرار می‌گیرد و از این طریق ادامه‌ی فرایند آموزش را تحت تأثیر قرار می‌دهد (هانگ و همکاران³، 2005).

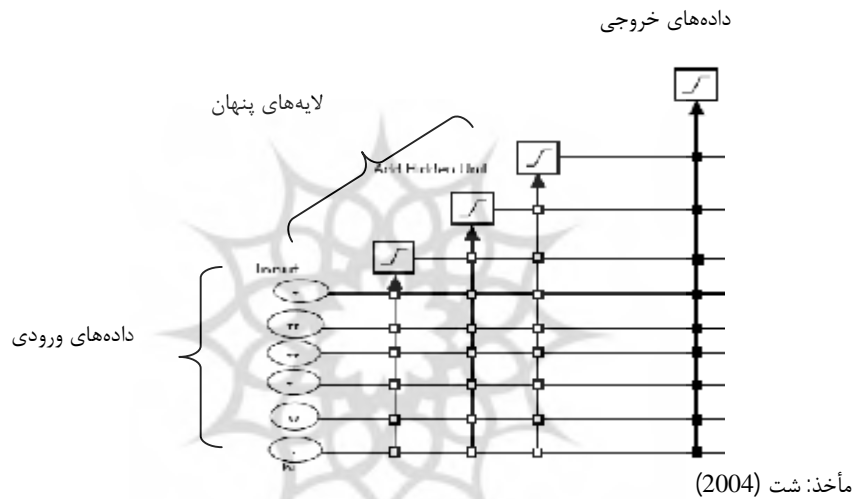
1- Ileana et al.

2- Elman Back Propagation Network.

3- Huang et al.

شبکه‌ی آبخاری پس انتشار¹

در نمودار (4)، شبکه‌ی آبخاری پس انتشار در حالت کلی و برای شبکه حاوی سه لایه‌ی پنهان ترسیم شده است. در این شبکه‌ها ابتدا آموزش بدون استفاده از نرون‌های لایه‌ی پنهان شروع شده و شبکه تا پایین‌ترین سطح خطای ممکن آموزش را ادامه می‌دهد. سپس یک لایه‌ی پنهان با تعدادی نرون به شبکه افزوده شده و آموزش شبکه ادامه می‌یابد و در گام‌های بعدی لایه‌های بعدی اضافه می‌شود (شست²، 2004).



نمودار 4- ساختار شبکه‌ی آبخاری پس انتشار با سه لایه‌ی پنهان

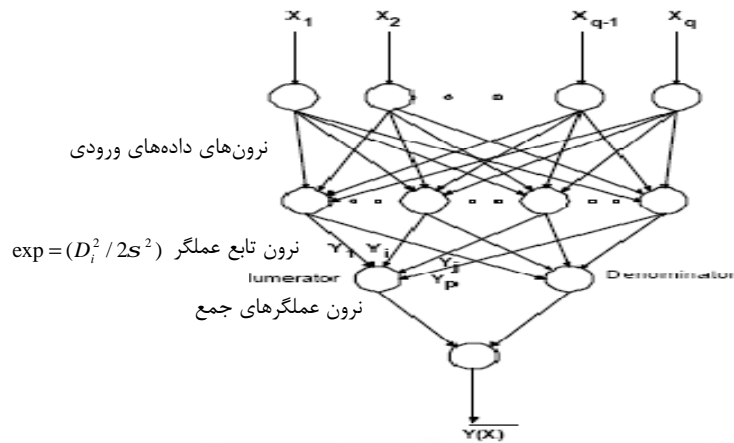
شبکه‌ی رگرسیون تعمیم یافته

ساختار کلی شبکه‌ی رگرسیون تعمیم یافته نیز به صورت زیر است (اسپکت³، 1991):

1- Cascade Back Propagation Network.

2- Shet.

3- Specht.



مأخذ: اسپکت (1991)

نمودار 5- ساختار شبکه‌ی رگرسیون تعمیم یافته¹

در شبکه‌ی رگرسیون تعمیم یافته از توابع زیر استفاده می‌شود:

$$D_i^2 = (X - X_i)^T \cdot (X - X_i) \quad \text{و} \quad Y(X) = \frac{\sum_{i=1}^n Y_i (D_i^2 / 2\sigma^2)}{\sum_{i=1}^n (D_i^2 / 2\sigma^2)} \quad (4)$$

در روابط فوق X بردار داده‌های ورودی، Y بردار داده‌های خروجی و σ یک پارامتر است که مقادیر متفاوتی را اختیار می‌کند. درحقیقت رابطه‌ی فوق رگرسیون کردن Y بر روی بردار X است.

براساس مطالعات، استفاده از لایه‌ی پنهان فراتر از سه عدد می‌تواند منجر به انطباق بیش از حد شود (کاسترا و بوید²، 1996)، لذا در این مطالعه از تعداد لایه‌های 1، 2 و 3 استفاده شده و همچنین دو تابع آموزش لونبرگ-مارکوات و شبه‌نیوتنی³ به کار رفته است.

1- Generalize Regression Network.

2- Kaastra and Boyd.

3- لازم به ذکر است که در ادبیات شبکه عصبی این واژه معادل Quasi Newton (BFG) می‌باشد.

3-2- الگوی خودرگرسیون میانگین متحرک¹

به‌طور کلی فرایندی را $ARIMA(p, q)$ گویند که شامل p مرتبه جمله خود رگرسیون و q مرتبه جمله میانگین متحرک باشد. به عبارت دیگر شامل p مرتبه جمله با وقفه از متغیر وابسته و q مرتبه جمله با وقفه از جملات اخلاص باشد. هم‌چنین اگر یک سری زمانی پس از d مرتبه تفاضل‌گیری ساکن شود و سپس آنرا توسط فرایند $ARIMA(p, q)$ مدل‌سازی کنیم، در این صورت سری زمانی اصلی، سری زمانی خود رگرسیونی میانگین متحرک انباشته $ARIMA(p, d, q)$ می‌باشد (گجراتی، 1378). یک مدل عمومی $ARIMA(p, q)$ عبارت است از:

$$y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (5)$$

انتخاب وقفه در الگوی خودرگرسیون میانگین متحرک

انتخاب وقفه از چالش‌زاترین مراحل پیش‌بینی الگوهای سری زمانی می‌باشد. مارسلینو و همکاران² (2006)، به‌منظور انتخاب وقفه در پیش‌بینی سری‌های ماهانه‌ی متغیرهای کلان اقتصاد آمریکا با استفاده از الگوی اتورگرسیو³ از چهار معیار استفاده کرد که شامل انتخاب وقفه‌ی ثابت 4، انتخاب وقفه‌ی ثابت 12، معیار آکائیک⁴ و معیار شوارتز⁵ بود. پیندک و رابینفلد⁶ (1998)، استفاده از ضرایب هبستگی جزئی را برای انتخاب وقفه یا مرتبه‌ی فرایند اتورگرسیو، مناسب عنوان کردند. پسران و پسران⁷ (1997)، به‌منظور تعیین وقفه، استفاده از معیار آکائیک را پیشنهاد دادند. بر این اساس آن‌ها استفاده از حداکثر 3 وقفه را برای پیش‌بینی سالیانه مناسب عنوان کردند. در مجموع می‌توان گفت استفاده از بیش از یک معیار و قضاوت نهایی بر اساس خطای پیش‌بینی، در بیش‌تر مطالعات مشهودترین نتیجه در ادبیات انتخاب وقفه می‌باشد. اما اندرس⁸ (2004)، در مقایسه با سایر مطالعات رهنمون کامل‌تری را ارائه کرده است.

1- Autoregressive Integrated Moving Average (ARIMA).

2- Marcellinio et al.

3- Autoregressive.

4- Akaike Criterion.

5- Schwarz Criterion.

6- Pindyck and Rubinfeld.

7- Pesaran.

8- Enderse.

روش ارایه شده در این رهیافت مبتنی بر ویژگی‌های تابع خود همبستگی¹ و تابع خودهمبستگی جزئی² است. این روش را در حالت کلی می‌توان به صورت زیر بیان کرد:

1. در یک فرآیند $ARIMA(p,q)$ ، تابع خود همبستگی پس از وقفه‌ی q محو می‌شود.

پس از این وقفه، خودهمبستگی کاهش می‌یابد. این کاهش را می‌توان با نگاه به ضریب

خودهمبستگی بررسی کرد.

2. در یک فرآیند $ARIMA(p,q)$ ، تابع خودهمبستگی جزئی پس از وقفه‌ی q محو

می‌شود.

بر اساس این روش در مورد برخی از سری‌ها می‌توان چند فرایند مختلف را بررسی و برای انتخاب از میان آن‌ها از معیارهایی همانند آکائیک، شوارتز، وجود یا عدم وجود خودهمبستگی میان جملات اخلاخل پس از برآورد فرایند موردنظر و نرمال بودن توزیع این جملات اخلاخل استفاده کرد. در این مطالعه به منظور انتخاب فرایند سری‌های تحت بررسی از روش پیشنهادی اندرس (2004)، استفاده شده است.

3-3- انتخاب بهترین مدل پیش‌بینی

برای تمامی روش‌های پیش‌بینی، ابتدا می‌بایست داده‌های سری مورد نظر را به دو قسمت تقسیم کرد. یک سری از آن‌ها معمولاً برای آموزش یا برازش مدل مورد استفاده قرار می‌گیرد که آن‌ها را اصطلاحاً داده‌های دستگرمی³ می‌گویند و سری دوم را که برای برای آزمون مدل به کار می‌روند را اصطلاحاً نمونه پیش‌بینی⁴ می‌نامند. داده‌های مورد استفاده برای پیش‌بینی در این مطالعه شامل سه گروه 10، 20 و 30 درصد می‌باشد. در حقیقت برای همه‌ی مدل‌های پیش‌بینی محاسبات بر مبنای داده‌های دستگرمی انجام می‌شود و به کمک داده‌های دوره‌ی پیش‌بینی مورد آزمون قرار می‌گیرد. روش‌های مختلفی برای اندازه‌گیری دقت مدل‌های پیش‌بینی وجود دارد رایج‌ترین آن‌ها معیار ریشه‌ی میانگین مجذور خطاهای پیش‌بینی⁵ است. هر مدلی که کم‌ترین مقدار از ریشه‌ی میانگین مجذور خطاهای پیش‌بینی را داشته باشد، به‌عنوان بهترین مدل

1 - Autocorrelation Function (ACF).

2 - Partial Autocorrelation Function (PACF).

3- Warm up.

4- Forecasting Sample.

5- Root Mean Squared Error (RMSE).

پیش‌بینی انتخاب می‌شود. در این بررسی نیز از معیار مزبور استفاده شده است. این معیار به صورت زیر است (پیندک و رابینفلد، 1998):

$$RMSE = \left(\sum_{i=T}^{T+h} (\hat{y}_t - y_t)^2 / h \right)^{1/2} \quad (6)$$

که در آن \hat{y}_t و y_t به ترتیب مقادیر پیش‌بینی شده و واقعی سری مورد پیش‌بینی هستند و h نیز تعداد مشاهدات مورد پیش‌بینی می‌باشد، T هم‌چنین داده‌های مورد استفاده برای انتخاب فرایند پیش‌بینی یا همان داده‌های دستگرمی می‌باشد. علاوه بر معیار فوق از دو معیار دیگر نیز استفاده شده است که عبارتند از، میانگین مطلق خطاها¹ و معیار درصد میانگین خطاهای پیش‌بینی².

مزیت استفاده از شاخص درصد میانگین خطاهای پیش‌بینی این است که وابسته به مقیاس نیست و امکان مقایسه‌ی قدرت پیش‌بینی را برای سری‌هایی که دارای مقیاس متفاوت هستند فراهم می‌کند. این شاخص‌ها به صورت زیر تعریف می‌شوند:

$$MAPE = \left(\sum_{t=T+1}^{T+h} |\hat{y}_t - y_t| / y_t / h \right) \quad (7)$$

هر چه مقادیر این دو شاخص پایین‌تر باشد، پیش‌بینی آرایه شده مطلوب‌تر خواهد بود. شاخص میانگین مطلق خطاها نیز به صورت زیر محاسبه می‌شود:

$$MAE = \left(\sum_{t=T+1}^{T+h} \hat{y}_t - y_t \right) / h \quad (8)$$

داده‌ها

برای آموزش شبکه‌های عصبی، افزون بر وقفه‌های مختلف قیمت نفت خام ایران از قیمت نفت‌های وست تگزاس اینترمدیت و برنت دریای شمال به عنوان نفت‌های مهم (یو و همکاران، 2008) استفاده شده است. پیش از استفاده از داده‌ها نیز پردازشی بر روی آن‌ها انجام گرفت، به این ترتیب که ابتدا نرخ تغییرات داده‌ها، محاسبه و بر حسب تغییرات مثبت و منفی به دو گروه تفکیک شد و با استفاده از یک متغیر موهومی این الگوی تغییرات در آموزش شبکه مورد استفاده قرار گرفت. در ادامه به منظور آموزش بهتر، شبکه‌ی داده‌ها تصادفی شدند. داده‌های مورد استفاده قیمت‌های هفتگی نفت خام

1- Mean Absolute Error (MAE).

2- Mean Absolute Percentage Error (MAPE).

ایران و شامل دوره‌ی ابتدای ژانویه 1997 تا انتهای مارس 2010، یعنی 690 مشاهده می‌باشد. این داده‌ها در قالب سه رویکرد مجزا برای پیش‌بینی مورد استفاده قرار گرفته است. به این ترتیب که در رویکرد اول، 90 درصد از داده‌ها برای آموزش (تخمین) و 10 درصد باقی مانده برای پیش‌بینی مورد استفاده قرار گرفته و در دو رویکرد دیگر، نسبت‌های یاد شده به ترتیب 20-80 و 30-70 بوده است. داده‌های مورد استفاده از پایگاه اطلاعاتی سازمان مدیریت اطلاعات انرژی ایالات متحده‌ی به دست آمده است. برای آموزش و پیش‌بینی شبکه‌های عصبی مصنوعی نیز از نرم افزار MATLAB7.1 استفاده شده است. تخمین الگوی رگرسیونی خودرگرسیون میانگین متحرک نیز با استفاده از نرم افزار Eviews5 انجام گرفته است.

4- یافته‌های تحقیق

به‌منظور تخمین الگوی رگرسیونی خودرگرسیون میانگین متحرک، ابتدا ایستایی داده‌ها بررسی شده است. نتایج آزمون ایستایی نشان داده است که این داده‌ها در سطح ایستا نیستند، اما پس از یک بار تفاضل‌گیری رفتاری ایستا نشان می‌دهند. یافته‌های مطالعه در دو قالب ارایه شده است. ابتدا خطای پیش‌بینی برای هر یک از شبکه‌ها آمده و در ادامه خطای پیش‌بینی شبکه‌ی دارای کم‌ترین خطای پیش‌بینی، ارایه شده است. در جدول (1)، به‌منظور سهولت مقایسه‌ی خطای پیش‌بینی تنها معیار درصد میانگین خطاهای پیش‌بینی ارایه شده است. برای شبکه‌هایی که با استفاده از 90 درصد از داده‌ها فرایند آموزش را انجام داده‌اند، میان دقت پیش‌بینی شبکه‌ی رگرسیون تعمیم یافته با سایر الگوها تفاوت بسیار بارزی وجود دارد. در مورد این گروه از شبکه‌ها شبکه‌ی پیشخور پس انتشار نسبت به نوع تابع آموزش حساسیت بالایی نشان می‌دهد. به گونه‌ای که با انتخاب شبه نیوتنی، شبکه نسبت به تعداد لایه‌های پنهان واکنش بسیار اندکی نشان داده است، اما در مورد تابع آموزش لونیبرگ-مارکوات، تعداد لایه‌ی پنهان بر دقت پیش‌بینی اثر بیشتری دارد. در مورد شبکه‌ی آبشاری پس انتشار، به نظر می‌رسد تعداد لایه‌ی پنهان بر دقت پیش‌بینی اثر بیشتری نسبت به تفاوت در تابع آموزش دارد، به گونه‌ای که با انتخاب سه لایه‌ی پنهان، صرف‌نظر از نوع تابع آموزش خطای پیش‌بینی کم‌ترین است. البته با انتخاب تابع آموزش شبه نیوتنی خطا به کم‌ترین حد خود می‌رسد. در مورد شبکه‌ی المان پس انتشار نیز هر چند در مورد شبکه‌ی دارای دو لایه‌ی پنهان و مبتنی بر تابع آموزش لونیبرگ-مارکوات، خطا نسبتاً

کم‌تر است، اما به‌طور کلی این شبکه نسبت به هر دو عامل تابع آموزش و تعداد لایه‌ی پنهان حساسیت کمی نشان داده است. در مورد شبکه‌ی المان پس انتشار و پیش‌بینی انتخاب تابع آموزش شبه‌ی نیوتنی موجب عدم حساسیت شبکه نسبت به تعداد لایه‌های پنهان شده است. به‌طور کلی می‌توان گفت تابع آموزش لونبرگ-مارکوات نسبت به تعداد لایه‌های پنهان در مقایسه با تابع آموزش شبه‌ی نیوتنی از حساسیت بالاتری برخوردار است. به‌طور کلی در ارزیابی شبکه‌های آرایه شده در جدول (1) می‌توان گفت بعد از شبکه‌ی رگرسیون تعمیم یافته که به‌طور قابل توجهی از دقت بسیار بالا در پیش‌بینی قیمت نفت خام ایران با استفاده از 90 درصد داده‌ها برخوردار است، شبکه‌ی آبخاری پس انتشار در اولویت بعدی قرار دارد و میان شبکه‌ی پیشخور پس انتشار و شبکه‌ی المان پس انتشار نیز تمایز زیادی نمی‌توان از نظر دقت پیش‌بینی قایل شد. دقت پیش‌بینی الگوی خودرگرسیون میانگین متحرک نیز با دو شبکه‌ی پیشخور پس انتشار و المان پس انتشار قابل مقایسه می‌باشد.

جدول 1- درصد خطای پیش‌بینی حاصل از پیش‌بینی قیمت نفت خام ایران با استفاده از الگوهای مختلف

شبه‌ی نیوتنی BFG			لونبرگ-مارکوات			نوع تابع آموزش	
3	2	1	3	2	1	تعداد لایه‌های پنهان درصد داده‌های پیش‌بینی	نوع الگو
3/76	3/71	3/71	3/41	4/48	3/66	10	شبکه‌ی پیشخور
4/03	3/36	3/37	3/42	3/20	3/68	20	پس انتشار
3/53	3/74	3/59	7/12	6/78	3/40	30	
1/86	3/03	3/07	2/68	3/20	3/65	10	شبکه‌ی آبخاری
4/43	3/74	3/37	3/42	4/09	3/65	20	پس انتشار
3/74	5/34	3/64	3/52	3/67	3/95	30	
3/72	3/71	3/71	3/68	3/30	3/65	10	شبکه‌ی المان
3/39	3/39	3/37	3/37	15/18	3/45	20	پس انتشار
3/66	3/84	3/59	3/60	3/67	3/64	30	
0/02						10	شبکه‌ی
4/35						20	رگرسیون تعمیم
4/85						30	یافته
3/82						10	الگوی
3/84						20	خودرگرسیون
3/40						30	میانگین متحرک

مأخذ: یافته‌های تحقیق

نتایج به دست آمده از الگوهایی که از 20 درصد داده‌ها برای پیش‌بینی استفاده کرده‌اند حاکی از آن است که در تمامی آن‌ها به‌طور کلی خطای پیش‌بینی بالاتر از 3 درصد است، اما نتایج در مورد شبکه‌های مورد استفاده نشان می‌دهد در صورتی که از تابع آموزش شبه‌ی نیوتنی استفاده شود، نه تنها اهمیت تعداد لایه‌ی پنهان، بلکه اهمیت نوع شبکه نیز چندان بالا نخواهد بود و در تمامی آن‌ها خطای پیش‌بینی به یکدیگر نزدیک است. خطای پیش‌بینی در مورد شبکه‌هایی که از تابع آموزش لونیبرگ-مارکوات استفاده کرده‌اند، دارای روند قابل تعقیبی نیست و تحت تأثیر هر دو پارامتر نوع شبکه و تعداد لایه‌ی پنهان قرار دارد. کم‌ترین خطای پیش‌بینی نیز به شبکه‌ی پیشخور پس انتشار مبتنی بر تابع آموزش لونیبرگ-مارکوات دارای دو لایه‌ی پنهان مربوط است. دقت پیش‌بینی شبکه‌ی رگرسیون تعمیم یافته و الگوی خودرگرسیون میانگین متحرک نیز برای پیش‌بینی 20 درصد از داده‌ها در سطح بالای قرار دارد.

در مورد شبکه‌هایی که از 70 درصد داده‌ها برای آموزش و 30 درصد برای پیش‌بینی استفاده کرده‌اند، شبکه‌ی المان پس انتشار، نسبت به نوع تابع آموزش و هم‌چنین تعداد لایه‌ی پنهان حساسیت چندان نشان نداده است و خطای پیش‌بینی در سطح 3/60-3/90 درصد قرار دارد. شرایط نسبتاً مشابه در مورد شبکه‌ی آبخاری پس انتشار نیز مشاهده می‌شود، با این تفاوت که برای شبکه‌ی دارای دو لایه‌ی پنهان تحت تابع آموزش شبه‌ی نیوتنی، بیش از 5 درصد خطا حاصل شده است، اما در شبکه‌ی پیشخور شرایط به گونه‌ی دیگری است. به این ترتیب که نسبت به نوع تابع آموزش حساسیت دارد، اما شبکه‌های دارای تابع آموزش شبه‌ی نیوتنی نسبت به تعداد لایه‌های پنهان حساسیتی نشان نمی‌دهند. بر خلاف این شبکه‌ها، شبکه‌های تحت تابع آموزش لونیبرگ-مارکوات نسبت به تعداد لایه‌های پنهان حساسیت بالایی نشان داده‌اند و با افزایش تعداد لایه‌های پنهان خطای پیش‌بینی در آن‌ها افزایش یافته است. خطای پیش‌بینی الگوی خودرگرسیون میانگین متحرک در مقایسه با بسیاری از شبکه‌ها در سطح پایین‌تری قرار دارد و می‌توان توانایی آن در پیش‌بینی 30 درصد از مشاهدات قیمت نفت خام را مطلوب ارزیابی کرد.

در جدول (2)، شبکه‌های حاوی کم‌ترین خطای پیش‌بینی برای پیش‌بینی 10 درصد از داده‌ها ارائه شده است. در زیرمجموعه‌ی شبکه‌های پیشخور پس انتشار،

جدول 2- نتایج حاصل از پیش‌بینی قیمت نفت خام ایران توسط الگوهای مختلف و با استفاده از 10 درصد داده‌ها

ویژگی‌ها	نوع الگو	شبکه‌ی پیشخور پس‌انتشار	شبکه‌ی آبخاری پس‌انتشار	شبکه‌ی المان پس‌انتشار	شبکه‌ی رگرسیون تعمیم یافته	الگوی خودرگرسیون میانگین متحرک
نوع تابع آموزش	لونیبرگ- مارکوات	لونیبرگ- مارکوات	شبه‌ی نیوتنی	لونیبرگ- مارکوات	-	-
تعداد لایه‌های پنهان	3	3	3	2	-	-
میانگین مجذور خطاهای پیش‌بینی	2/56	1/63	2/44	0/4	2/93	
میانگین مطلق خطاها	1/99	1/16	1/89	0/2	2/23	
درصد میانگین خطاهای پیش‌بینی	3/41	1/86	3/30	0/2	3/82	
میانگین (61/96)	61/86	62	61/90	61/96	61/65	
واریانس (192/57)	183/33	195/85	189/38	192/63	204/56	
رتبه	4	2	3	1	5	

مأخذ: یافته‌های تحقیق

کم‌ترین خطای پیش‌بینی با استفاده از تابع آموزش لونیبرگ- مارکوات و با استفاده از 3 لایه‌ی پنهان حاصل شده است. در مورد شبکه‌ی آبخاری پس‌انتشار، هر چند تعداد سه لایه‌ی پنهان توصیه شده، اما استفاده از تابع آموزش شبه‌ی نیوتنی ترجیح داده شده است. شبکه‌ی المان پس‌انتشار نیز استفاده از تابع آموزش لونیبرگ- مارکوات و تعداد دو لایه‌ی پنهان را به‌عنوان دقیق‌ترین الگوی پیش‌بینی خود پیشنهاد کرده است. به این ترتیب مشاهده می‌شود که در سه نوع شبکه‌ی یاد شده، استفاده از بیش از 1 لایه‌ی پنهان مورد توجه است. در میان تمامی الگوهای مندرج در جدول (2)، شبکه‌ی رگرسیون تعمیم یافته با دقتی بالاتر از 99 درصد یا خطایی کمتر از 1 درصد، دارای بهترین عملکرد بوده است. برای پیش‌بینی 10 درصد داده‌ها شبکه‌ی آبخاری پس‌انتشار نیز با خطایی کمتر از 2 درصد در رتبه‌ی بعدی قرار دارد. شبکه‌ی المان پس‌انتشار و شبکه‌ی پیشخور پس‌انتشار نیز با خطایی کمتر از 3/5 درصد در رتبه‌های بعدی قرار دارند. در نهایت نیز الگوی خودرگرسیون میانگین متحرک قرار گرفته که خطای آن اندکی کمتر از 4 درصد به دست آمده است. میانگین مقادیر پیش‌بینی شده

بسیار نزدیک به میانگین مقادیر حقیقی است و واریانس سری پیش‌بینی شده در برخی از الگوها، از واریانس مقادیر حقیقی حتی کم‌تر به دست آمده است. در جدول (3)، نیز یافته‌های مشابه برای پیش‌بینی 20 درصد از داده‌ها آمده است.

جدول 3- نتایج حاصل از پیش‌بینی قیمت نفت خام ایران توسط الگوهای مختلف و با استفاده از 20 درصد داده‌ها

نوع الگو ویژگی‌ها	شبکه‌ی پیش‌خور پس انتشار	شبکه‌ی آبخاری پس انتشار	شبکه‌ی المان پس انتشار	شبکه‌ی رگرسیون تعمیم یافته	الگوی خودرگرسیون میانگین متحرک
نوع تابع آموزش	لونبرگ- مارکوات	شبه‌ی نیوتنی BFG	لونبرگ- مارکوات	-	-
تعداد لایه‌های پنهان	1	3	3	-	-
میانگین مجذور خطاهای پیش‌بینی	2/23	2/36	2/20	2/37	3/70
میانگین مطلق خطاها	1/46	1/52	1/46	2/11	2/83
درصد میانگین خطاهای پیش‌بینی	3/37	3/42	3/37	4/35	3/84
میانگین (44/23)	44/05	44/13	44/05	44/23	78/08
واریانس (875/63)	869/77	870/13	872/54	851/92	568/11
رتبه	2	3	1	4	5

مأخذ: یافته‌های تحقیق

برای سه الگوی اول جدول که دارای تابع آموزش و تعداد لایه‌های مختلف هستند، از نظر نوع تابع آموزش میان نتایج این جدول و جدول قبل تشابه کامل وجود دارد، اما از نظر تعداد لایه‌ی پنهان تفاوت دیده می‌شود. از نظر دقت پیش‌بینی بر اساس هر سه معیار، به سختی می‌توان میان شبکه‌ی پیش‌خور پس انتشار و شبکه‌ی المان پس انتشار تفاوت قایل شد، لذا می‌توان این دو شبکه را با خطایی کم‌تر از 3/5 درصد دارای بالاترین دقت در پیش‌بینی 20 درصد از داده‌ها ارزیابی کرد. خطای پیش‌بینی شبکه‌ی آبخاری پس انتشار نیز تنها اندکی بالاتر از دو شبکه یاد شده می‌باشد. شبکه‌ی رگرسیون تعمیم یافته بر خلاف توانایی خود در پیش‌بینی 10 درصد داده‌ها، در مورد 20 درصد از داده‌ها دارای بالاترین خطا در میان شبکه‌های آرایه شده در جدول (3) است و بیش از 4 درصد خطای پیش‌بینی دارد. به این ترتیب در مورد 20 درصد از داده‌ها، خطای پیش‌بینی در حداقل خود ما یعنی در سطح کم‌تر از 3/5 درصد قرار دارد.

در جدول (4) نیز دقیق‌ترین پیش‌بینی هر یک از انواع شبکه‌ها ارائه شده است. به جز شبکه‌ی رگرسیون تعمیم یافته، در مورد تمامی سایر الگوها خطای پیش‌بینی در دامنه‌ی کوتاه 3/60-3/40 درصد قرار دارد. شبکه‌ی پیش‌خور پس انتشار و شبکه‌ی آبشاری پس انتشار، از تابع آموزش لونیبرگ-مارکوات استفاده کرده‌اند، اما در شبکه‌ی المان پس انتشار، استفاده از شبه نیوتنی کم‌ترین خطای پیش‌بینی را داشته است. هم‌چنین در مورد پیش‌بینی‌های به دست آمده برای 20 و 30 درصد داده‌ها، مقادیر میانگین و واریانس بسیار نزدیک به مقدار آن‌ها برای سری حقیقی قیمت نفت خام به دست آمده است.

جدول 4- نتایج حاصل از پیش‌بینی قیمت نفت خام ایران توسط الگوهای مختلف و با استفاده از 30 درصد داده‌ها

نوع الگو ویژگی‌ها	شبکه‌ی پیش‌خور پس انتشار	شبکه‌ی آبشاری پس انتشار	شبکه‌ی المان پس انتشار	شبکه‌ی رگرسیون تعمیم یافته	الگوی خودرگرسیون میانگین متحرک
نوع تابع آموزش	لونیبرگ- مارکوات	لونیبرگ- مارکوات	شبه‌ی نیوتنی BFG	-	-
تعداد لایه‌های پنهان	1	3	1	-	-
میانگین مجذور خطاهای پیش‌بینی	1/94	1/95	1/95	3/15	3/21
میانگین مطلق خطاها	1/29	1/32	1/33	2/03	2/39
درصد میانگین خطاهای پیش‌بینی	3/40	3/52	3/59	4/85	3/40
میانگین (38/40)	38/48	38/48	38/47	38/46	72/60
واریانس (587/22)	574/27	575/75	573/68	574/03	453/05
رتبه	1	2	3	4	5

مأخذ: یافته‌های تحقیق

5- نتیجه‌گیری و پیشنهادات

اهمیت نفت خام موجب شده است تا بسیاری از مطالعات به پیش‌بینی قیمت آن بپردازند و روش‌ها نیز همواره در جهت افزایش دقت پیش‌بینی‌ها یاری کرده‌اند. با توجه به این‌که افق مورد استفاده در آموزش و پیش‌بینی، در این مطالعات با مطالعات گذشته

تفاوت دارد، لذا امکان مقایسه‌ی خطای پیش‌بینی تنها با مطالعاتی وجود دارد که خطای پیش‌بینی را بر حسب درصد بیان کرده‌اند. در میان مطالعات مرور شده، تنها مطالعه‌ی اصفهانیان و امین ناصری (1387) دارای چنین ویژگی بود که در آن مطالعه خطای پیش‌بینی در شبکه دارای کم‌ترین خطا $3/48$ درصد به دست آمد. در حالی که در مطالعه‌ی حاضر برای پیش‌بینی 10 درصد داده‌ها این رقم کم‌تر از 1 درصد و در مورد 20 و 30 درصد داده‌ها نیز حدود $3/4$ درصد به دست آمده است. هم‌چنین همانند مطالعات یو و همکاران (2008)، فرجام نیا و همکاران (1386) و شریف‌النبی (1378)، برتری پیش‌بینی‌های شبکه‌ی عصبی بر خودرگرسیون میانگین متحرک مشخص شده است.

در مورد یافته‌های به دست آمده برای پیش‌بینی قیمت نفت خام ایران، می‌توان گفت به‌طور کلی با افزایش داده‌های پیش‌بینی از 10 به 20 درصد، تغییرات مهم پیش روی عمدتاً به‌صورت تغییر در تعداد لایه‌های پنهان و البته کاهش دقت پیش‌بینی است، اما با افزایش آن‌ها به فراتر از 20 درصد، دقت پیش‌بینی اندکی کاهش نشان می‌دهد. هم‌چنین در ساختار شبکه نیز تغییرات در هر دو زمینه‌ی نوع تابع آموزش و تعداد لایه‌ی پنهان مشهود است. برای پیش‌بینی 10 درصد از داده‌های قیمت نفت خام، الگوهای شبکه‌ی رگرسیون تعمیم یافته و شبکه‌ی آبخاری پس انتشار با تابع آموزش شبه‌ی نیوتنی و سه لایه‌ی پنهان دارای خطای کم‌تری در مقایسه با سایر شبکه‌ها هستند و با استفاده از آن‌ها می‌توان به ترتیب با خطایی کم‌تر از 1 و کم‌تر از 2 درصد قیمت نفت خام را پیش‌بینی کرد، لذا استفاده از این شبکه‌ها برای پیش‌بینی 10 درصد داده‌ها بر سایر شبکه‌ها اولویت دارد. برای پیش‌بینی 10 و 20 درصد داده‌های قیمت نفت خام ایران با استفاده از شبکه‌ی پیشخور پس انتشار و شبکه‌ی المان پس انتشار، به‌کارگیری تابع آموزش لونبرگ-مارکوات بر تابع آموزش شبه‌ی نیوتنی ترجیح دارد و معمولاً این شبکه‌ها به استفاده از تعداد لایه‌ی پنهان بالا تمایل دارند، اما در مورد 30 درصد از داده‌ها هم نظر از نوع تابع آموزش و هم از نظر تعداد لایه‌ی پنهان به‌ویژه برای شبکه‌ی المان پس انتشار، تفاوت‌هایی دیده می‌شود. به این ترتیب پیشنهاد می‌شود در پیکربندی شبکه، به دنبال افزایش درصد داده‌های پیش‌بینی به فراتر از 20 درصد، تفاوت‌های یاد شده مورد توجه قرارگیرد. به‌طور کلی بر اساس بیش‌تر معیارهای بررسی، دقت پیش‌بینی الگوهای شبکه‌ی عصبی مصنوعی بر الگوی رگرسیونی خودرگرسیون

میانگین متحرک برتری دارد، بنابراین استفاده از الگوهای شبکه‌ی عصبی یاد شده بر الگوی خودرگرسیون میانگین متحرک ارجحیت دارد. شبکه‌ی رگرسیون تعمیم یافته بر خلاف توانایی بالای خود در پیش‌بینی 10 درصد داده‌ها، در مورد پیش‌بینی مقادیر بالاتر داده‌ها توانایی بسیار پایینی نشان می‌دهد، لذا استفاده از آن تنها در افق 10 درصد از داده‌ها توصیه می‌شود. به‌طور نسبی با افزایش درصد داده‌های مورد استفاده در پیش‌بینی و کاهش درصد داده‌های مورد استفاده در آموزش شبکه، دقت پیش‌بینی رو به افول می‌گذارد، که این کاهش دقت با حرکت از 10 درصد به 20 درصد بسیار محسوس‌تر از افزایش داده‌های پیش‌بینی از 20 به 30 درصد می‌باشد، لذا پیشنهاد می‌شود تا حد امکان به استفاده از افق 10 درصد داده‌ها اکتفا شود.

فهرست منابع

- ابریشمی، حمید. معینی، علی. مهرآرا، محسن. احراری، مهدی. و فاطمه. سلیمانی‌کیا. (1386). مدل سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه‌ی عصبی GMDH. فصل‌نامه‌ی پژوهش‌های اقتصادی ایران. سال دوازدهم. شماره‌ی 36: 58-37.
- ابریشمی، حمید. مهرآرا، محسن. و یاسمین. آریانا. (1387). ارزیابی عملکرد مدل‌های پیش‌بینی بی‌ثباتی قیمت نفت. مجله‌ی تحقیقات اقتصادی. شماره‌ی 78: 21-1.
- اصفهانیان، مجید (1382)، ارایه‌ی یک مدل شبکه‌ی عصبی جهت پیش‌بینی قیمت نفت خام، پایان‌نامه‌ی کارشناسی ارشد، گروه مهندسی صنایع، دانشگاه تربیت مدرس.
- اصفهانیان، مجید. و محمد. رضا. امین ناصری. (1387). ارایه‌ی یک مدل شبکه‌ی عصبی جهت پیش‌بینی کوتاه مدت قیمت نفت خام. ویژه‌نامه‌ی مهندسی صنایع. شماره‌ی 1. جلد 19: 35-27.
- بانک مرکزی ایران، پایگاه اطلاع‌رسانی. <http://www.cbi.org>,
- بهراد مهر، نفیسه. (1387). پیش‌بینی قیمت نفت خام با استفاده از هموارسازی مویک و شبکه‌ی عصبی مصنوعی. فصل‌نامه‌ی مطالعات اقتصاد انرژی. سال پنجم. شماره‌ی 18: 81-98.

شریف‌النبی، مصطفی (1378)، کاربرد شبکه‌های عصبی در پیش‌بینی: مطالعه‌ی موردی پیش‌بینی قیمت نفت، پایان‌نامه‌ی کارشناسی ارشد، گروه مدیریت، دانشگاه شیراز.

فرجام‌نیا، ایمان. ناصری، محسن. و سیدمحمد مهدی. احمدی. (1386). پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی. فصل‌نامه‌ی پژوهش‌های اقتصادی ایران. سال نهم. شماره‌ی 32: 161-183.

گجراتی، دامودار (1378)، مبانی اقتصادسنجی، جلد دوم، ترجمه‌ی حمید ابریشمی، انتشارات دانشگاه تهران، تهران.

منهاج، محمد باقر (1377)، مبانی شبکه‌های عصبی (هوش محاسباتی)، نشر دکتر حسابی، تهران.

Enderse, W (2004), *Applied Econometrics Time Series*, John Wiley and Sons, Inc.

Huang, W., Nakamori, Y. And Wang, S. Y. (2005). Forecasting Stock Market Movement Direction with Support Vector Machine. *Computers and Operations Research*, 32: 2513–2522.

Ileana, I., Rotar, C. And Incze, A. (2004). The Optimization of Feed Forward Neural Networks Structure Using Genetic Algorithms. *International Conference on Theory and Applications of Mathematics and Informatics*. Thessaloniki, Greece. 223-234.

Kaastra, I. And Boyd, M. (1996). Designing a Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing*, 10: 215-236.

Kaboudan, M. A. (2001), *Computetric Forecasting Of Crude Oil Price*, IEEE, 283-287.

Kang., S. H. Kang. S. M. And Yoon, S. M. (2009). Forecasting Volatility of Crude Oil Markets. *Energy Economics*, 31: 119–125

Lanza, A., Manera, M. and Giovannini, M. (2005). Modeling And Forecasting Cointegrated Relationships Among Heavy Oil And Product Prices. *Energy Economics*, 27: 831– 848.

- Malik, F. And Nasereddin, M. (2006). Forecasting Output Using Oil Prices: A Cascaded Artificial Neural Network Approach. *Journal of Economics and Business*, 58: 168–180.
- Marcellinio, M., Stock, J. H. And M. W. Watson, (2006), A Comparison Of Direct And Indirect And Iterated Multi Step AR Methods For Forecasting Macroeconomic Time Series, *Journal Of Econometrics*, 135: 499-526.
- Morana, C. (2001). A Semi Parametric Approach to Short-Term Oil Price Forecasting. *Energy Economics*, 23: 325-338.
- Pesaran, H.M. and B. Pesaran, (1994). *Working With Microfit 4.0: An Introduction to Econometrics*, Oxford University Press, Oxford.
- Pindyck, R. S. And Rubinfeld, D. L. (1998), *A Computer Handbook Using Eviews*, Fourth Edition, Mcgraw-Hill.
- Rech, G. (2002). Forecasting With Artificial Neural Network Models, *SSE/EFI Working Paper Series in Economics and Finance*, No. 491: 2-4.
- Shet, R. N. (2004). *Neural Network Based Analysis and Prediction of Deformation in Line Drawing*. Department Of Computer Science. Loughborough University. Leicestershire, United Kingdom.
- Specht, D. F. (1991). A General Regression Neural Network. *IEEE Transactions on Neural Network*. VOL. 2. NO. 6: 568-576.
- U. S. Energy Information Administration. (2010). [Http://Tonto.Eia.Doe.Gov](http://Tonto.Eia.Doe.Gov)
- Wickham P. (1996). Volatility of Oil Prices, *International Monetary Fund Working Papers*, 96/82.
- Wu, SH. I. And R. P. Lu (1995), Combining Artificial Neural Networks And Statistics For Stock-Market Forecasting, 257-264.
- Yu, L., Wang, S. And Lai, K. K. (2008). Forecasting Crude Oil Price with an EMD-Based Neural Network Ensemble Learning Paradigm. *Energy Economics*, 30: 2623–2635.