

فصلنامه‌ی مطالعات اقتصاد انرژی / سال هشتم / شماره‌ی ۲۸ / بهار ۱۳۹۰ / صفحات ۱۱۸-۹۷

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

سید ابوالحیم 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: ۸۹/۳/۴ تاریخ پذیرش: ۸۹/۸/۱۸

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 ۱۹۹۷-۲۰۱۰ می‌باشد و پیش‌بینی‌ها برای ۱۰، ۲۰ و ۳۰ درصد داده‌های یاد شده انجام گرفته است. الگوهای مورد استفاده برای پیش‌بینی، شامل ۴ الگوی شبکه‌ی عصبی و یک الگوی رگرسیونی (خودرگرسیون) میانگین متحرک بوده است. شبکه‌های منتخب شامل شبکه‌ی پیشخور پس انتشار، شبکه‌ی آبشاری پس انتشار، شبکه‌ی المان پس انتشار و شبکه‌ی رگرسیون تعیین یافته می‌باشد. همچنین توابع آموزش مورد استفاده در پیش‌بینی شامل توابع لونبرگ- مارکوآت و شبه‌ی نیوتونی است. یافته‌های به دست آمده نشان می‌دهد برای پیش‌بینی ۱۰ درصد از داده‌های قیمت نفت خام، الگوهای شبکه‌ی رگرسیون تعیین یافته و شبکه‌ی آبشاری پس انتشار با تابع آموزش شبکه‌ی نیوتونی، به ترتیب با خطای کمتر از ۱ و کمتر از ۲ درصد دارای بهترین عملکرد هستند. برای پیش‌بینی ۲۰ درصد داده‌های قیمت نفت خام ایران، شبکه‌ی پیشخور پس انتشار و شبکه‌ی المان پس انتشار با تابع آموزش لونبرگ- مارکوآت، دارای عملکرد بهتر می‌باشد. در مورد ۳۰ 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 بهویشه با افزایش از ۱۰ درصد به ۲۰ 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

۱- مقدمه

انرژی، نهادهای استرانژیک در فرایند تولید است که تغییرات قیمت آن بر اقتصاد تمام جهان تأثیرگذار می‌باشد. در میان کشورهای عرضه کننده همانند ایران، اثر آن بر درآمدهای ارزی بسیار حایز اهمیت است. در دوره‌ی ۱۳۳۸-۶۹، به جز در سال ۱۳۵۹ همواره بیش از ۸۰ درصد از درآمد ارزی ایران از محل فروش نفت حاصل شده است. در دوره‌ی ۱۳۷۰-۸۲ نیز این رقم تنها کمتر از ۶۹ درصد کاهش یافته است (بانک مرکزی ایران، ۱۳۸۶). اتکای بالا به درآمد ارزی نفت، افزون بر پدیده‌ی بیماری هلندی، موجب آسیب پذیری 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، به عنوان مثال در حالی که قیمت نفتخام ایران در جولای سال ۲۰۰۸ به بیش از ۱۳۶ دلار در هر بشکه افزایش یافته بود، اما تنها کمتر از ۶ ماه بعد از آن به کمتر از ۴۰ دلار کاهش یافت (سازمان مدیریت اطلاعات انرژی ایالات متحده، ۲۰۱۰). 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 به صورت 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 به عنوان یک ابزار مهم، بهویژه در کوتاه مدت مورد توجه سیاستگذاران قرار گیرد. این شناخت رفتار می‌تواند به صورت پیش‌بینی روند تغییرات آن‌ها در آینده باشد. امروزه ابزارهای مناسبی برای این منظور در دسترس هستند که می‌توانند پیش‌بینی‌های مطلوبی ارایه کنند.

در ادامه، در بخش ۲، پیشینه‌ی تحقیق، بخش ۳، روش شناسی تحقیق، بخش ۴، یافته‌های تحقیق و بخش ۵، نتیجه‌گیری و پیشنهادات، ارائه می‌گردد.

۲- 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 به طور خاص استفاده از دو گروه از الگوهای مشهود است. در برخی از آن‌ها تلاش شده است تا رفتار نوسانات قیمت نفت با استفاده از الگوهای رگرسیونی، شناسایی و این طریق پیش‌بینی‌هایی ارایه شود. بررسی نوسانات قیمت جهانی نفت توسط ویکام^۱ (۱۹۹۶)، مورانا^۲ (۲۰۰۱)، لانزا و همکاران^۳ (۲۰۰۵) و کانگ و همکاران^۴ (۲۰۰۹) و همچنین بررسی نوسانات قیمت نفت وست تگزاس اینترمیدیت^۵ (WTI) توسط ابریشمی و همکاران (۱۳۸۶)، از جمله‌ی این مطالعات هستند. نکته‌ی حائز اهمیت در این مطالعات وجود ویرگی موسوم به اثر خودرگرسیون با واریانس ناهمسانی شرطی^۶ می‌باشد که امکان بیان رفتار نوسان قیمت نفت را فرآهنم 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 امریکا (کبودان^۷، ۲۰۰۱)، پیش‌بینی قیمت نفت وست تگزاس اینترمیدیت و برنت (یو و همکاران^۸، ۲۰۰۸)، پیش‌بینی قیمت جهانی نفت (فرجام نیا و همکاران، ۱۳۸۶)، پیش‌بینی قیمت نفت خام نیویورک و خلیج مکریک (بهراهمهر، ۱۳۸۷)، پیش‌بینی قیمت نفت خام ایران (اصفهانیان، ۱۳۸۲؛ اصفهانیان و امین ناصری، ۱۳۸۷) و همچنین پیش‌بینی قیمت بنزین بازار سنگاپور (ابریشمی و همکاران، ۱۳۸۷) 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 (۲۰۰۸)، فرجام نیا و همکاران (۱۳۸۶) و همچنین شریف‌النبی (۱۳۷۸)، 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 Intermediat.

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 نفت خام ایران در اقتصاد ایران، این مطالعه با هدف پیش‌بینی قیمت نفت خام ایران و یافتن الگوی مناسب برای پیش‌بینی انجام گرفته است. ویژگی متمایز مطالعه‌ی حاضر در مقایسه با مطالعات مورود 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 تعیین کننده وست تگزاس اینترمدیت و برنت در آموزش شبکه، از دیگر ویژگی‌های بارز مطالعه‌ی حاضر است.

۳- روش‌شناسی تحقیق

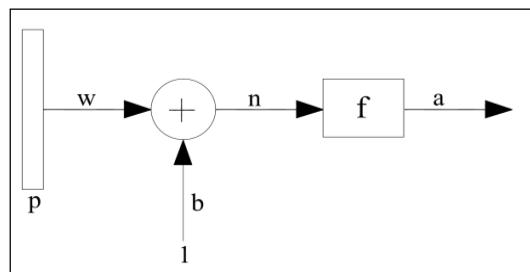
در این بخش روش شبکه‌های عصبی مصنوعی، الگوی خودرگرسیون میانگین متحرک و نحوه انتخاب بهترین مدل پیش‌بینی کننده، معرفی و تشریح می‌گردد.

۳-۱- شبکه‌های عصبی مصنوعی^۱

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، کوچک ترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد (منهاج، ۱۳۷۷). هر یک از نرون‌ها، ورودی‌ها را دریافت و پس از پردازش روی آن‌ها، یک سیگنال خروجی تولید می‌کند، لذا هر نرون در شبکه به عنوان مرکز پردازش و توزیع اطلاعات عمل محسوب می‌شود و ورودی و خروجی مخصوص به خود را دارد (وو و لو^۲. ۱۹۹۵). شکل (۱)، نمایش ساختار

1- Artificial Neural Networks.
2- Wu and Lu.

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



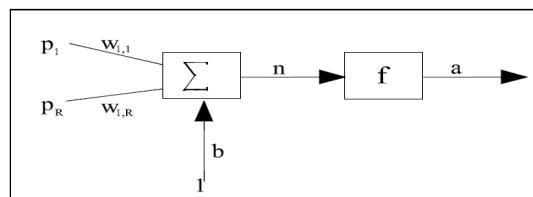
مأخذ: منهج (۱۳۷۷)

نمودار ۱- مدل نرون تک ورودی

میزان تأثیر p روی a به وسیله‌ی مقدار عدد w تعیین می‌شود. ورودی دیگر، مقدار ثابت 1 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 (محرك) f ، است. بدین ترتیب خروجی نرون به صورت معادله‌ی (۱) تعریف می‌شود:

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

پارامترهای w و b قابل تنظیم هستند و تابع محرك 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 (۲)، مدل یک نرون با R ورودی نشان داده شده است.



مأخذ: منهج (۱۳۷۷)

نمودار ۲- مدل چند ورودی یک نرون

در شکل (۲)، عده‌های P_i عناصر بردار ورودی هستند و با ماتریس وزن W و جمله‌ی اریب (b)، ورودی خالص را به صورت رابطه‌ی (۹) تشکیل می‌دهند:

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

که در آن $W = [W_{1,1}, W_{1,2}, \dots, W_{1,R}]^T$ و $\bar{P} = [P_1, P_2, \dots, P_R]^T$ و در نهایت خروجی نرون به صورت رابطه‌ی (۳) خواهد بود:

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

معمول‌آیکی نرون حتی با تعداد ورودی‌های زیاد نیز به تنها یکی برای حل مسائل کفایت نمی‌کند (منهاج، ۱۳۷۷)، 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 آشیاری پس انتشار است. به عنوان مثال کبودان (۲۰۰۱) و همچنین یو و همکاران (۲۰۰۸)، شبکه‌ی پیشخور پس انتشار را پیشنهاد و مالیک و ناصرالدین^۱ (۲۰۰۶)، شبکه‌ی آشیاری پس انتشار را مناسب ارزیابی کردند. شبکه‌ی پیشخور پس انتشار در مطالعه‌ی اصفهانیان (۱۳۸۲) و اصفهانیان و ناصری (۱۳۸۷) 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 (۱۳۸۷) مورد توجه قرار گرفته بودند، استفاده شدند که در ادامه معرفی می‌شوند.

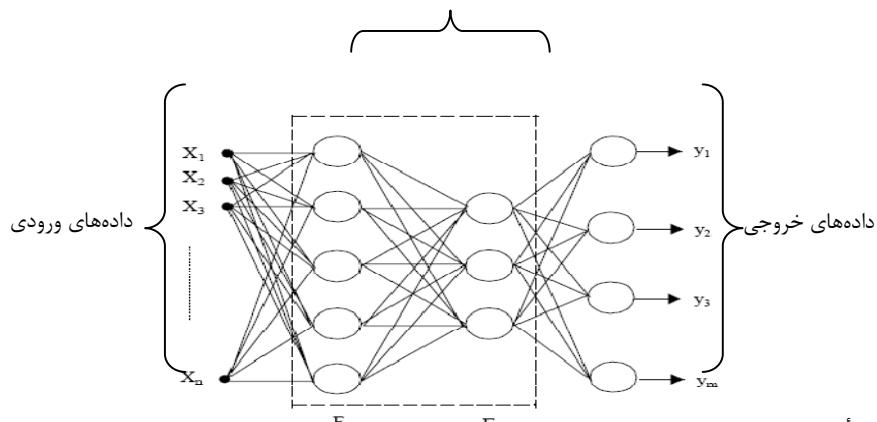
شبکه‌ی پیشخور پس انتشار^۲

در نمودار (۳)، 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.

لایه‌های پنهان



نمودار ۳- 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 عملکرگ است که پردازش بر روی داده‌ها را انجام می‌دهد (ایلینا و همکاران^۱، ۲۰۰۴).

شبکه‌یelman پس انتشار^۲

شبکه‌یelman نیز دارای ساختاری مشابه شبکه‌ی پیشخور پس انتشار است، اما از نظر نوع عملکرد با آن دارای تفاوت است. به این ترتیب که شبکه‌یelman 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 همکاران^۳، ۲۰۰۵).

1- Ileana et al.

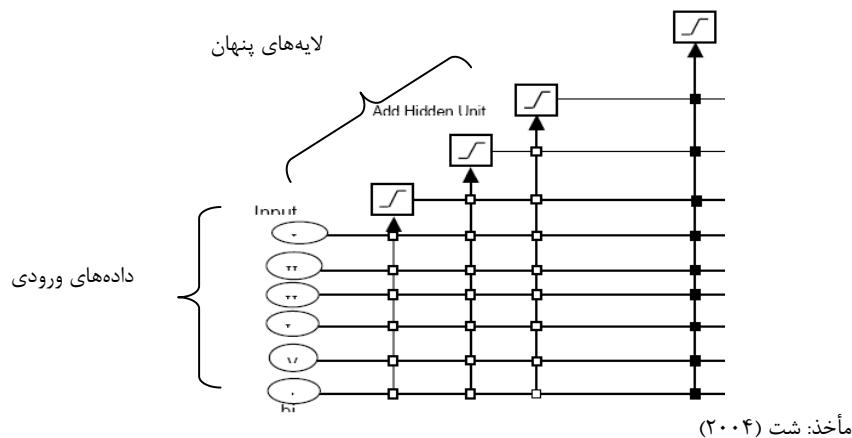
2- Elman Back Propagation Network.

3- Huang et al.

شبکه‌ی آبشاری پس انتشار^۱

در نمودار (۴)، شبکه‌ی آبشاری 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 پایین ترین 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 (شت.^۲، ۲۰۰۴).

داده‌های خروجی



شبکه‌ی رگرسیون تعمیم یافته

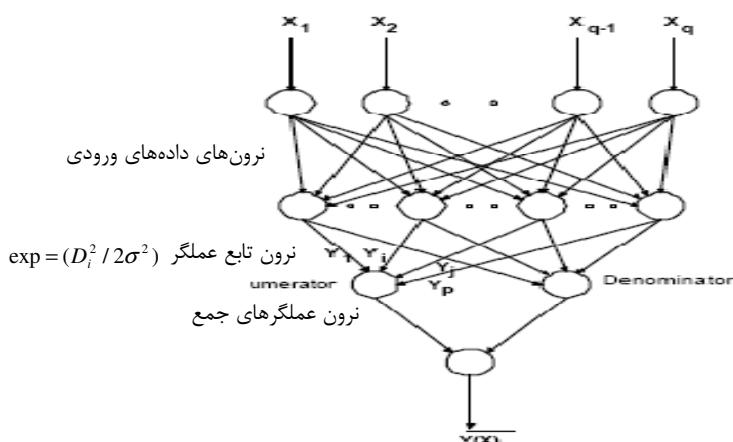
ساختار کلی شبکه‌ی رگرسیون تعمیم یافته نیز به صورت زیر است (اسپکت^۳،

:۱۹۹۱)

1- Cascade Back Propagation Network.
2- Shet.
3- Specht.

۱۰۵

ارزیابی عملکرد الگوهای شبکه‌ی عصبی و خودرگرسیون میانگین متحرک ...



مأخذ: اسپکت (۱۹۹۱)

نمودار ۵- ساختار شبکه‌ی رگرسیون تعمیم یافته^۱

در شبکه‌ی رگرسیون تعمیم یافته از توابع زیر استفاده می‌شود:

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

در روابط فوق X بردار داده‌های ورودی، Y بردار داده‌های خروجی و σ یک پارامتر است که مقادیر متفاوتی را اختیار می‌کند. در حقیقت رابطه‌ی فوق رگرس کردن Y ببروی بردار X است.

براساس مطالعات، استفاده از لایه‌ی پنهان فراتر از سه عدد می‌تواند منجر به انطباق بیش از حد شود (کاسترا و بوید^۲، ۱۹۹۶)، لذا در این مطالعه از تعداد لایه‌های ۱، ۲ و ۳ استفاده شده و همچنین دو تابع آموزش لونبرگ-مارکوآت و شبیه‌ی نیوتنی^۳ 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.

۳- الگوی خودرگرسیون میانگین متحرک^۱

بهطور کلی فرایندی را ARIMA (p,q) گویند که شامل p مرتبه جمله خود رگرسیون و q مرتبه جمله‌ی میانگین متحرک باشد. به عبارت دیگر شامل p مرتبه جمله با وقفه از متغیر وابسته و q مرتبه جمله با وقفه از جملات اخلال باشد. همچنان اگر یک سری زمانی پس از d مرتبه تفاضل‌گیری ساکن شود و سپس آن را توسط فرایند ARIMA (p, q) مدل‌سازی کنیم، در این صورت سری زمانی اصلی، سری زمانی خود رگرسیونی میانگین متحرک انباسته ARIMA (p, d, q) می‌باشد (گجراتی، ۱۳۷۸). یک مدل عمومی ARIMA (p, q) عبارت است از:

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

انتخاب وقفه در الگوی خودرگرسیون میانگین متحرک

انتخاب وقفه از چالش‌زنترین مراحل پیش‌بینی الگوهای سری زمانی می‌باشد. مارسلینیو و همکاران^۲ (۲۰۰۶)، بهمنظور انتخاب وقفه در پیش‌بینی سری‌های ماهانه‌ی متغیرهای کلان اقتصاد آمریکا با استفاده از الگوی اتورگرسیو^۳ از چهار معیار استفاده کرد که شامل انتخاب وقفه‌ی ثابت^۴، انتخاب وقفه‌ی ثابت ۱۲، معیار آکائیک^۵ و معیار شوارتز^۶ بود. پیندک و رابینفلد^۷ (۱۹۹۸)، استفاده از ضرایب هبستگی جزیی را برای انتخاب وقفه یا مرتبه‌ی فرایند اتورگرسیو، مناسب عنوان کردند. پسران و پسران^۸ (۱۹۹۷)، بهمنظور تعیین وقفه، استفاده از معیار آکائیک را پیشنهاد دادند. بر این اساس آن‌ها استفاده از حداکثر^۹ 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 اندرس^{۱۰} (۲۰۰۴)، در مقایسه با سایر مطالعات رهنمون کامل‌تری را ارایه 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 همبستگی^۱ و تابع خودهمبستگی جزیی^۲ است. این روش را در حالت کلی می‌توان به صورت زیر بیان کرد:

۱. در یک فرآیند ARIMA(p,q), تابع خود همبستگی پس از وقفه‌ی q محو می‌شود.
۲. در یک فرآیند ARIMA(p,q), تابع خودهمبستگی جزیی 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 اخلال پس از برآورده فرایند موردنظر و نرمال بودن توزیع این جملات اخلال استفاده کرد. در این مطالعه به منظور انتخاب فرایند سری‌های تحت بررسی از روش پیشنهادی اندرس (۲۰۰۴)، استفاده شده است.

۳-۳- 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 برآمدگاری مدل مورد استفاده قرار می‌گیرد که آن‌ها را اصطلاحاً داده‌های دستگرمی^۳ می‌گویند و سری دوم را که برای برای آزمون مدل به کار می‌رود را اصطلاحاً نمونه پیش‌بینی^۴ می‌نامند. داده‌های مورد استفاده 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 دقیقت مدل‌های پیش‌بینی وجود دارد رایج‌ترین آن‌ها معیار ریشه‌ی میانگین مجذور خطاهای پیش‌بینی^۵ است. هر مدلی که کمترین مقدار از ریشه‌ی میانگین مجذور خطاهای پیش‌بینی را داشته باشد، به عنوان 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، ۱۹۹۸):

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

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 هم‌چنان 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 خطاهای^۱ و معیار درصد میانگین خطاهای پیش‌بینی^۲.

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

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

هر چه مقادیر این دو شاخص پایین‌تر باشد، پیش‌بینی ارایه شده مطلوب‌تر خواهد بود. شاخص میانگین مطلق خطاهای 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، ۲۰۰۸) 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 زانویه ۱۹۹۷ تا انتهای مارس ۲۰۱۰، یعنی ۶۹۰ مشاهده می‌باشد. این داده‌ها در قالب سه رویکرد مجزا برای پیش‌بینی مورد استفاده قرار گرفته است. به این ترتیب که در رویکرد اول، ۹۰ درصد از داده‌ها برای آموزش (تخمین) و ۱۰ درصد باقی مانده برای پیش‌بینی مورد استفاده قرار گرفته و در دو رویکرد دیگر، نسبت‌های یاد شده به ترتیب ۸۰-۲۰ و ۷۰-۳۰ 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.

۴- یافته‌های تحقیق

به منظور 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 (۱)، به منظور سهولت مقایسه‌ی خطای پیش‌بینی تنها معیار درصد میانگین خطاهای پیش‌بینی ارایه شده است. برای شبکه‌هایی که با استفاده از ۹۰ 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 نیوتینی، شبکه نسبت به تعداد لایه‌های پنهان واکنش بسیار اندکی نشان داده است، اما در مورد تابع آموزش لونبرگ- مارکوآت، 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 نیوتینی خطأ 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 لونبرگ- مارکوآت، خطأ نسبتاً

کمتر است، اما به طور 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 شبکه‌ی نیوتونی موجب عدم حساسیت شبکه نسبت به تعداد لایه‌های پنهان شده است. به طور کلی می‌توان گفت تابع آموزش لونبرگ- مارکوآت نسبت به تعداد لایه‌های پنهان در مقایسه با تابع آموزش شبکه نیوتونی از حساسیت بالاتری برخوردار است. به طور کلی در ارزیابی شبکه‌های ارایه شده در جدول (۱) می‌توان گفت بعد از شبکه‌ی رگرسیون تعمیم یافته که به طور قابل توجهی از دقت بسیار بالا در پیش‌بینی قیمت نفت خام ایران با استفاده از ۹۰ درصد داده‌ها برخوردار است، شبکه‌ی آبشاری 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 قابل شد. دقت پیش‌بینی الگوی خودرگرسیون میانگین متحرک نیز با دو شبکه‌ی پیش‌خور پس انتشار و المان پس انتشار قابل مقایسه باشد.

جدول ۱- درصد خطای پیش‌بینی حاصل از پیش‌بینی قیمت نفت خام ایران با استفاده از الگوهای مختلف

| نوع تابع آموزش | | | | | | | | | | |
|--------------------------------|------|------|----------------|-------|------|------------------------|--|--|--|--|
| لونبرگ- مارکوآت | | | شبکه‌ی نیوتونی | | | | | | | |
| BFG | لک | لایه | لک | لایه | لک | لایه | | | | |
| ۳ | ۲ | ۱ | ۳ | ۲ | ۱ | نوع الگو | | | | |
| ۳/۷۶ | ۳/۷۱ | ۳/۷۱ | ۳/۴۱ | ۴/۴۸ | ۳/۶۶ | تعداد لایه‌های پنهان | | | | |
| ۴/۰۳ | ۳/۳۶ | ۳/۳۷ | ۳/۴۲ | ۳/۲۰ | ۳/۶۸ | درصد داده‌های پیش‌بینی | | | | |
| ۳/۵۳ | ۳/۷۴ | ۳/۵۹ | ۷/۱۲ | ۶/۷۸ | ۳/۴۰ | شبکه‌ی پیش‌خور | | | | |
| ۱/۱۸۶ | ۳/۰۳ | ۳/۰۷ | ۲/۶۸ | ۳/۲۰ | ۳/۶۵ | پس انتشار | | | | |
| ۴/۴۳ | ۳/۷۴ | ۳/۳۷ | ۳/۴۲ | ۴/۰۹ | ۳/۶۵ | شبکه‌ی آبشاری | | | | |
| ۳/۷۴ | ۵/۳۴ | ۳/۶۴ | ۳/۵۲ | ۳/۶۷ | ۳/۹۵ | پس انتشار | | | | |
| ۳/۷۲ | ۳/۷۱ | ۳/۷۱ | ۳/۶۸ | ۳/۳۰ | ۳/۶۵ | شبکه‌ی المان | | | | |
| ۳/۳۹ | ۳/۳۹ | ۳/۳۷ | ۳/۳۷ | ۱۵/۱۸ | ۳/۴۵ | پس انتشار | | | | |
| ۳/۶۶ | ۳/۸۴ | ۳/۵۹ | ۳/۶۰ | ۳/۶۷ | ۳/۶۴ | | | | | |
| ۰/۰۲ | | | ۱۰ | | | | | | | |
| ۴/۳۵ | | | ۲۰ | | | | | | | |
| ۴/۸۵ | | | ۳۰ | | | | | | | |
| ۲/۸۲ | | | ۱۰ | | | | | | | |
| ۳/۸۴ | | | ۲۰ | | | | | | | |
| ۳/۴۰ | | | ۳۰ | | | | | | | |
| شبکه‌ی رگرسیون تعمیم یافته | | | | | | | | | | |
| الگوی خودرگرسیون میانگین متحرک | | | | | | | | | | |

مأخذ: یافته‌های تحقیق

نتایج به دست آمده از الگوهایی که از ۲۰ درصد داده‌ها برای پیش‌بینی استفاده کرده‌اند حاکی از آن است که در تمامی آن‌ها به طور کلی خطای پیش‌بینی بالاتر از ۳ درصد است، اما نتایج در مورد شبکه‌های مورد استفاده نشان می‌دهد در صورتی که از تابع آموزش شبکه‌ی نیوتونی 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 لونبرگ-مارکوآت 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 لونبرگ-مارکوآت دارای دو لایه‌ی پنهان مربوط است. دقت پیش‌بینی شبکه‌ی رگرسیون تعییم یافته و الگوی خودرگرسیون میانگین متحرک نیز برای پیش‌بینی ۲۰ درصد از داده‌ها در سطح بالایی قرار دارد.

در مورد شبکه‌هایی که از ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای پیش‌بینی استفاده کرده‌اند، شبکه‌ی المان پس انتشار، نسبت به نوع تابع آموزش و هم‌چنین تعداد لایه‌ی پنهان حساسیت چندانی نشان نداده است و خطای پیش‌بینی در سطح $3/60-3/90$ درصد قرار دارد. شرایط نسبتاً مشابه در مورد شبکه‌ی آبشاری پس انتشار نیز مشاهده می‌شود، با این تفاوت که برای شبکه‌ی دارای دو لایه‌ی پنهان تحت تابع آموزش شبکه‌ی نیوتونی، بیش از ۵ درصد خطای 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 شبکه‌ی نیوتونی نسبت به تعداد لایه‌های پنهان حساسیتی نشان نمی‌دهند. بر خلاف این شبکه‌ها، شبکه‌های تحت تابع آموزش لونبرگ-مارکوآت 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 ۳۰ درصد از مشاهدات قیمت نفت خام را مطلوب ارزیابی کرد.

در جدول (۲)، شبکه‌های حاوی کمترین خطای پیش‌بینی برای پیش‌بینی ۱۰ درصد از داده‌ها ارایه شده است. در زیرمجموعه‌ی شبکه‌های پیشخور پس انتشار،

جدول ۲- نتایج حاصل از پیش‌بینی قیمت نفت خام ایران توسط الگوهای مختلف و با استفاده از ۱۰ درصد داده‌ها

| الگوی خودرگرسیون میانگین متحرک | شبکه‌ی رگرسیون تعمیم یافته | شبکه‌ی آبشاری پس انتشار | شبکه‌ی پیشخور پس انتشار | شبکه‌ی پیشخور پس انتشار | نوع الگو ویژگی‌ها |
|--------------------------------|----------------------------|-------------------------|-------------------------|-------------------------|-----------------------------|
| - | - | لونبرگ- مارکوآت | شبه‌ی نیوتونی | لونبرگ- مارکوآت | نوع تابع آموزش |
| - | - | ۲ | ۳ | ۳ | تعداد لایه‌های پنهان |
| ۲/۹۳ | ۰/۴ | ۲/۴۴ | ۱/۶۳ | ۲/۵۶ | میانگین مجرد خطاها پیش‌بینی |
| ۲/۲۲ | ۰/۲ | ۱/۸۹ | ۱/۱۶ | ۱/۹۹ | میانگین مطلق خطاها |
| ۳/۸۲ | ۰/۲ | ۳/۳۰ | ۱/۸۶ | ۳/۴۱ | درصد میانگین خطاها پیش‌بینی |
| ۶۱/۶۵ | ۶۱/۹۶ | ۶۱/۹۰ | ۶۲ | ۶۱/۸۶ | میانگین (۶۱/۹۶) |
| ۲۰۴/۵۶ | ۱۹۲/۶۳ | ۱۸۹/۳۸ | ۱۹۵/۸۵ | ۱۸۳/۳۳ | واریانس (۱۹۲/۵۷) |
| ۵ | ۱ | ۳ | ۲ | ۴ | رتبه |

مأخذ: یافته‌های تحقیق

کمترین خطای پیش‌بینی با استفاده از تابع آموزش لونبرگ- مارکوآت و با استفاده از ۳ لایه‌ی پنهان حاصل شده است. در مورد شبکه‌ی آبشاری پس انتشار، هر چند تعداد سه لایه‌ی پنهان توصیه شده، اما استفاده از تابع آموزش شبه‌ی نیوتونی ترجیح داده شده است. شبکه‌ی المان پس انتشار نیز استفاده از تابع آموزش لونبرگ- مارکوآت و تعداد دو لایه‌ی پنهان را به عنوان دقیق‌ترین الگوی پیش‌بینی خود پیشنهاد کرده است. به این ترتیب مشاهده می‌شود که در سه نوع شبکه‌ی یاد شده، استفاده از بیش از ۱ لایه‌ی پنهان مورد توجه است. در میان تمامی الگوهای مندرج در جدول (۲)، شبکه‌ی رگرسیون تعمیم یافته با دقیق‌تر از ۹۹ درصد یا خطای کمتر از ۱ درصد، دارای بهترین عملکرد بوده است. برای پیش‌بینی ۱۰ درصد داده‌ها شبکه‌ی آبشاری پس انتشار نیز با خطای کمتر از ۲ درصد در رتبه‌ی بعدی قرار دارد. شبکه‌ی المان پس انتشار و شبکه‌ی پیشخور پس انتشار نیز با خطای کمتر از ۳/۵ درصد در رتبه‌های بعدی قرار دارند. در نهایت نیز الگوی خودرگرسیون میانگین متحرک قرار گرفته که خطای آن اندکی کمتر از ۴ درصد به دست آمده است. میانگین مقادیر پیش‌بینی شده بسیار

نرده‌یک به میانگین مقادیر حقیقی است و واریانس سری پیش‌بینی شده در برخی از الگوهای از واریانس مقادیر حقیقی حتی کمتر به دست آمده است. در جدول (۳)، نیز یافته‌های مشابه برای پیش‌بینی ۲۰ درصد از داده‌ها آمده است.

جدول ۳- نتایج حاصل از پیش‌بینی قیمت نفت خام ایران توسط الگوهای مختلف و با استفاده از ۲۰ 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 | لوبنبرگ- شبه‌ی نیوتونی BFG | لوبنبرگ- مارکوآت | - | - | - |
| تعداد لایه‌های پنهان | ۳ | ۳ | ۳ | - | - |
| میانگین مجدد خطاهای پیش‌بینی | ۲/۲۰ | ۲/۲۷ | ۲/۲۰ | ۲/۳۶ | ۳/۷۰ |
| میانگین مطلق خطاهای پیش‌بینی | ۲/۸۲ | ۲/۱۱ | ۱/۴۶ | ۱/۵۲ | ۲/۸۴ |
| درصد میانگین خطاهای پیش‌بینی | ۴/۳۵ | ۴/۳۷ | ۳/۴۲ | ۳/۳۷ | ۴۴/۲۳ |
| میانگین (۴۴/۲۳) | ۴۴/۲۳ | ۴۴/۰۵ | ۴۴/۱۳ | ۴۴/۰۵ | ۷۸/۰۸ |
| واریانس (۸۷۵/۶۳) | ۸۵۱/۹۲ | ۸۷۲/۵۴ | ۸۷۰/۱۳ | ۸۶۹/۷۷ | ۵۶۸/۱۱ |
| رتبه | ۵ | ۴ | ۱ | ۳ | ۲ |

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 قابل شد، لذا می‌توان این دو شبکه را با خطای کمتر از ۳/۵ درصد دارای بالاترین دقت در پیش‌بینی ۲۰ درصد از داده‌ها ارزیابی کرد. خطای پیش‌بینی شبکه‌ی آبشاری پس انتشار نیز تنها اندکی بالاتر از دو شبکه یاد شده می‌باشد. شبکه‌ی رگرسیون تعییم یافته برخلاف توانایی خود در پیش‌بینی ۱۰ درصد داده‌ها، در مورد ۲۰ درصد از داده‌ها دارای بالاترین خطای در میان شبکه‌های ارایه شده در جدول (۳) است و بیش از ۴ درصد خطای پیش‌بینی دارد. به این ترتیب در مورد ۲۰ درصد از داده‌ها، خطای پیش‌بینی در حداقل خود ما یعنی در سطح کمتر از ۳/۵ درصد قرار دارد.

در جدول (۴) نیز دقیق‌ترین پیش‌بینی هر یک از انواع شبکه‌ها ارایه شده است. به جز شبکه‌ی رگرسیون تعمیم یافته، در مورد تمامی سایر الگوهای خطای پیش‌بینی در دامنه‌ی کوتاه ۳/۶۰-۳/۴۰ درصد قرار دارد. شبکه‌ی پیشخور پس انتشار و شبکه‌ی آبشاری پس انتشار، از تابع آموزش لونبرگ- مارکوآت استفاده کرده‌اند، اما در شبکه‌ی المان پس انتشار، استفاده از شبکه نیوتونی کمترین خطای پیش‌بینی را داشته است. همچنین در مورد پیش‌بینی‌های به دست آمده برای ۲۰ و ۳۰ درصد داده‌ها، مقادیر میانگین و واریانس بسیار نزدیک به مقدار آن‌ها برای سری حقیقی قیمت نفت خام به دست آمده است.

جدول ۴- نتایج حاصل از پیش‌بینی قیمت نفت خام ایران توسط الگوهای مختلف و با استفاده از ۳۰ درصد داده‌ها

| الگوی خودرگرسیون میانگین متحرک | شبکه‌ی رگرسیون تعمیم یافته | شبکه‌ی المان پس انتشار | شبکه‌ی آبشاری پس انتشار | شبکه‌ی پیشخور پس انتشار | نوع الگو ویژگی‌ها |
|--------------------------------|----------------------------|------------------------|-------------------------|-------------------------|-------------------------------|
| - | - | شبکه نیوتونی BFG | لوبنبرگ- مارکوآت | لوبنبرگ- مارکوآت | نوع تابع آموزش |
| - | - | ۱ | ۳ | ۱ | تعداد لایه‌های پنهان |
| ۳/۲۱ | ۳/۱۵ | ۱/۹۵ | ۱/۹۵ | ۱/۹۴ | میانگین مجذور خطاهای پیش‌بینی |
| ۲/۳۹ | ۲/۰۳ | ۱/۳۳ | ۱/۳۲ | ۱/۲۹ | میانگین مطلق خطاهای |
| ۳/۴۰ | ۴/۸۵ | ۳/۵۹ | ۳/۵۲ | ۳/۴۰ | درصد میانگین خطاهای پیش‌بینی |
| ۷۲/۶۰ | ۳۸/۴۶ | ۳۸/۴۷ | ۳۸/۴۸ | ۳۸/۴۸ | میانگین (۳۸/۴۰) |
| ۴۵۳/۰۵ | ۵۷۴/۰۳ | ۵۷۳/۶۸ | ۵۷۵/۷۵ | ۵۷۴/۲۷ | واریانس (۵۸۷/۲۲) |
| ۵ | ۴ | ۳ | ۲ | ۱ | رتیبه |

مأخذ: یافته‌های تحقیق

۵- نتیجه‌گیری و پیشنهادات

اهمیت نفت خام موجب شده است تا بسیاری از مطالعات به پیش‌بینی قیمت آن بپردازنند 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 (۱۳۸۷) 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 ۱۰ درصد داده‌ها این رقم کمتر از ۱ درصد و در مورد ۲۰ و ۳۰ درصد داده‌ها نیز حدود $3/4$ درصد به دست آمده است. همچنانی همانند مطالعات یو و همکاران (۲۰۰۸)، فرجام نیا و همکاران (۱۳۸۶) و شریف‌النبی (۱۳۷۸)، 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 ۱۰ به ۲۰ درصد، تغییرات مهم پیش روی عمده‌تا به صورت تغییر در تعداد لایه‌های پنهان و البته کاهش دقت پیش‌بینی است، اما با افزایش آن‌ها به فراتر از ۲۰ درصد، دقت پیش‌بینی اندکی کاهش نشان می‌دهد. همچنانی در ساختار شبکه نیز تغییرات در هر دو زمینه‌ی نوع تابع آموزش و تعداد لایه‌ی پنهان مشهود است. برای پیش‌بینی ۱۰ درصد از داده‌های قیمت نفت خام، الگوهای شبکه‌ی رگرسیون تعیین یافته و شبکه‌ی آبشاری پس انتشار با تابع آموزش شبه‌ی نیوتونی و سه لایه‌ی پنهان دارای خطای کمتری در مقایسه با سایر شبکه‌ها هستند و با استفاده از آن‌ها می‌توان به ترتیب با خطای کمتر از ۱ و کمتر از ۲ درصد قیمت نفت خام را پیش‌بینی کرد، لذا استفاده از این شبکه‌ها برای پیش‌بینی ۱۰ درصد داده‌ها بر سایر شبکه‌ها اولویت دارد. برای پیش‌بینی ۱۰ و ۲۰ درصد داده‌های قیمت نفت خام ایران با استفاده از شبکه‌ی پیشخور پس انتشار و شبکه‌ی المان پس انتشار، به کارگیری تابع آموزش لونبرگ-مارکوآت بر تابع آموزش شبه نیوتونی ترجیح دارد و معمولاً این شبکه‌ها به استفاده از تعداد لایه‌ی پنهان بالا تمایل دارند، اما در مورد ۳۰ 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 ۲۰ درصد، تفاوت‌های یاد شده مورد توجه قرار گیرد. 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 برخلاف توانایی بالای خود در پیش‌بینی ۱۰ درصد داده‌ها، در مورد پیش‌بینی مقادیر بالاتر داده‌ها توانایی بسیار پایینی نشان می‌دهد، لذا استفاده از آن تنها در افق ۱۰ 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 ۱۰ درصد به ۲۰ درصد بسیار محسوس‌تر از افزایش داده‌های پیش‌بینی از ۲۰ به ۳۰ درصد می‌باشد، لذا پیشنهاد می‌شود تا حد امکان به استفاده از افق ۱۰ درصد داده‌ها اکتفا شود.

فهرست منابع

- ابریشمی، حمید. معینی، علی. مهرآرا، محسن. احراری، مهدی. و فاطمه. سلیمانی کیا. (۱۳۸۶). مدل سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه‌ی عصبی GMDH. *فصلنامه‌ی پژوهش‌های اقتصادی ایران*. سال دوازدهم، شماره‌ی ۳۶: ۵۸-۳۷.
- ابریشمی، حمید. مهرآرا، محسن. و یاسمین. آریانا. (۱۳۸۷). ارزیابی عملکرد مدل‌های پیش‌بینی بی ثباتی قیمت نفت. *مجله‌ی تحقیقات اقتصادی*. شماره‌ی ۷۸: ۲۱-۱.
- اصفهانیان، مجید (۱۳۸۲)، ارایه‌ی یک مدل شبکه‌ی عصبی جهت پیش‌بینی قیمت نفت خام، پایان نامه‌ی کارشناسی ارشد، گروه مهندسی صنایع، دانشگاه تربیت مدرس.
- اصفهانیان، مجید. و محمد. رضا. امین ناصری. (۱۳۸۷). ارایه‌ی یک مدل شبکه‌ی عصبی جهت پیش‌بینی کوتاه مدت قیمت نفت خام. *ویژه‌نامه‌ی مهندسی صنایع* شماره‌ی ۱. جلد ۱۹: ۳۵-۲۷.
- بانک مرکزی ایران، پایگاه اطلاع‌رسانی. <http://www.cbi.org>
- بهزاد مهر، نفیسه. (۱۳۸۷). پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و شبکه‌ی عصبی مصنوعی. *فصلنامه‌ی مطالعات اقتصاد انرژی*. سال پنجم، شماره‌ی ۱۸: ۹۸-۸۱.

شريف النبی، مصطفی (۱۳۷۸)، کاربرد شبکه‌های عصبی در پیش‌بینی: مطالعه‌ی موردی پیش‌بینی قیمت نفت، پایان نامه‌ی کارشناسی ارشد، گروه مدیریت، دانشگاه شیراز.

فرجام نیا، ایمان، ناصری، محسن، و سیدمحمد‌هدی، احمدی، (۱۳۸۶). پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی، فصلنامه‌ی پژوهش‌های اقتصادی ایران، سال نهم، شماره‌ی ۳۲: ۱۸۳-۱۶۱.

گجراتی، دامودار (۱۳۷۸)، مبانی اقتصادسنجی، جلد دوم، ترجمه‌ی حمید ابریشمی، انتشارات دانشگاه تهران، تهران.

منهاج، محمد باقر (۱۳۷۷)، مبانی شبکه‌های عصبی (هوش محاسباتی)، نشر دکتر حسابی، تهران.

Enderse, W (2004), Applicec 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), Compumetric 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.
- Marcellino, 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.