

معرفی الگوهای مناسب پیش‌بینی قیمت گازوییل

حمید محمدی

استادیار گروه کشاورزی دانشگاه زابل
hamidmohammadi1378@gmail.com

زکریا فرج‌زاده

دانشجوی دکتری دانشگاه شیراز
zakariafarajzadeh@gmail.com

این مطالعه با هدف معرفی الگوهای مطلوب پیش‌بینی برای قیمت گازوییل در بازار انرژی سنگاپور به عنوان بازار مؤثر بر قیمت گازوییل در خاورمیانه انجام شد. داده‌های مورد استفاده به صورت هفتگی و شامل دوره (۲۰۱۰-۱۹۸۷) می‌باشد. پیش‌بینی‌ها برای ۱۰، ۲۰ و ۳۰ درصد داده‌ها صورت گرفت. الگوهای مورد استفاده برای پیش‌بینی شامل چهار الگوی شبکه عصبی و یک الگوی رگرسیونی (خودرگرسیون میانگین متحرک) بود. شبکه‌های منتخب شامل شبکه پیشخور پس‌انتشار، شبکه آبخاری پس‌انتشار، شبکه المان پس‌انتشار و شبکه رگرسیون تعمیم‌یافته می‌باشد. همچنین، توابع آموزش مورد استفاده در پیش‌بینی شامل توابع لونیبرگ-مارکوات و شبه‌نیوتنی است. یافته‌ها در مورد تمام گروه از داده‌ها، کمترین خطای پیش‌بینی در شبکه را نشان دادند که از تابع آموزش لونیبرگ-مارکوات استفاده می‌کند. همچنین، مشخص شد برای پیش‌بینی ۲۰ و ۳۰ درصد داده‌ها شبکه المان پس‌انتشار و برای پیش‌بینی ۱۰ درصد داده‌ها شبکه پیشخور پس‌انتشار دارای کمترین خطای پیش‌بینی هستند. همچنین، نتایج نشان دادند شبکه رگرسیون تعمیم‌یافته و الگوی رگرسیونی خودرگرسیون میانگین متحرک در مقایسه با سه شبکه دیگر از دقت قابل رقابتی برخوردار نیستند. البته یافته‌های آماره دیبلد-ماریانو نشان دادند که میان شبکه‌های دارای کمترین خطای پیش‌بینی از لحاظ آماری تفاوت معناداری در دقت پیش‌بینی وجود ندارد. برای قیمت گازوییل به طور نسبی استفاده از ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای پیش‌بینی در مقایسه با سایر ترکیب از داده‌ها خطای پیش‌بینی کمتر نشان داد. بر اساس نتایج به دست آمده می‌توان با استفاده از شبکه‌های پیشنهادی مطالعه به پیش‌بینی‌هایی با خطای حدود ۲ درصد دست یافت.

طبقه‌بندی JEL: C45, C53, Q49.

واژه‌های کلیدی: قیمت پیش‌بینی گازوییل، شبکه عصبی مصنوعی، خودرگرسیون میانگین متحرک.

۱. مقدمه

انرژی نهاده‌ای استراتژیک در فرایند تولید است که تغییرات قیمت آن بر اقتصاد تمام جهان تأثیرگذار است و اثر آن بر درآمدهای ارزی در میان کشورهای عرضه‌کننده همانند ایران بسیار حائز اهمیت است. با توجه به رابطه نزدیک گازوییل با نفت خام شرایط این محصول از شرایط بازار نفت بطور کامل متأثر می‌گردد. نفت خام در برخی از مواقع نوسان بسیار گسترده‌ای را طی نموده است. به عنوان مثال، در حالی که قیمت نفت خام ایران در جولای سال ۲۰۰۸ به بیش از ۱۳۶ دلار در هر بشکه افزایش یافته بود، اما تنها کمتر از شش ماه پس از آن به کمتر از ۴۰ دلار کاهش یافت. ضریب تغییرات نفت خام در دوره (۲۰۱۰-۱۹۹۷) برابر با ۱۶ می‌باشد، اما این ضریب در دوره یادشده برای قیمت گازوییل در بازار سنگاپور به‌عنوان بازار تأثیرگذار بر بازار گازوییل خاورمیانه بیش از ۴۷ است (سازمان مدیریت اطلاعات انرژی ایالات متحده، ۲۰۱۰). این رقم حاکی از نوسان‌هایی گسترده‌تر در بازار گازوییل می‌باشد. با توجه به گستردگی استفاده از گازوییل در بخش تولید به ویژه در بخش‌های آسیب‌پذیر و زیربنایی مانند حمل‌ونقل، نوسان قیمت آن می‌تواند آثار مستقیم و غیرمستقیم قابل ملاحظه‌ای داشته باشد.

در ایران گازوییل به صورت یارانه‌ای و توسط دولت توزیع می‌شود، اما با توجه به تلاش دولت در جهت حذف یارانه گازوییل در آینده تغییرات قیمت آن نیز باید بیش از گذشته به منظور دستیابی به اهداف برنامه‌های اقتصادی موردتوجه قرار گیرد. اعتقاد بر این است که بازار انرژی سنگاپور بر قیمت انرژی در خاورمیانه تأثیر عمده‌ای دارد (ابریشمی و همکاران، ۱۳۸۷). همچنین با توجه به اینکه برای بازار خاورمیانه قیمت دیگری در دسترس نبود لذا برای پیش‌بینی قیمت گازوییل از قیمت گازوییل در بازار سنگاپور استفاده شده است. برای مقابله با شرایط پرنوسان قیمت گازوییل علاوه بر تلاش در جهت یافتن جایگزین‌هایی برای نقش‌های ایفایی این منبع انرژی که البته یک راه‌حل بلندمدت است. تلاش در جهت شناخت بیشتر رفتار آنها نیز می‌تواند به عنوان یک ابزار مهم به ویژه در کوتاه‌مدت موردتوجه سیاستگذاران قرار گیرد. این شناخت رفتار می‌تواند آنها را در جهت پیش‌بینی رفتار مساعدت نماید. امروزه ابزارهای مناسبی برای این منظور در دسترس است که می‌تواند پیش‌بینی‌های مطلوبی ارائه نماید.

در خصوص پیش‌بینی قیمت انرژی عمدتاً قیمت نفت موردتوجه بوده است. این در حالی است که الگوی نوسان فرآورده‌های آن همچون گازوییل تفاوت‌های بارزی دارد. استفاده از الگوهای جدید پیش‌بینی برای انواع حامل‌های انرژی و از جمله قیمت نفت خام نیز بیانگر اهمیت قابل ملاحظه پیش‌بینی قیمت انرژی است. در خصوص پیش‌بینی قیمت نفت خام به طور خاص استفاده از دو گروه از الگوها مشهود است. در برخی از آنها تلاش شده است تا رفتار نوسان‌های قیمت نفت با استفاده از الگوهای

رگرسیون شناسایی و از این طریق پیش‌بینی‌هایی ارائه شود. بررسی نوسان‌های قیمت جهانی نفت توسط ویکام (۱۹۹۶)، مورانا (۲۰۰۱)، لانزا و همکاران (۲۰۰۵) و کانگ و همکاران (۲۰۰۹) و همچنین بررسی نوسان‌های قیمت نفت وست تگزاس اینترمدیت^۱ توسط ابریشمی و همکاران (۱۳۸۶) از جمله این مطالعات هستند. نکته حائز اهمیت در این مطالعات، وجود ویژگی موسوم به اثر خودرگرسیون با واریانس ناهمسانی شرطی^۲ است که امکان بیان رفتار نوسان قیمت نفت را فراهم نموده است. هرچند وجود نوسان گسترده امکان استفاده از چنین الگوی رگرسیونی را مقدور نموده است، اما پیشرفت‌های اخیر در زمینه مدل‌های پیش‌بینی دقت پیش‌بینی‌ها را به صورت قابل توجهی افزایش داده است. شبکه عصبی مصنوعی از جمله این روش‌ها است که به صورت گسترده برای پیش‌بینی قیمت بسیاری از متغیرهای اقتصادی و از جمله قیمت انرژی مورد استفاده قرار گرفته است.

پیش‌بینی قیمت نفت خام آمریکا (کبودان، ۲۰۰۱)، پیش‌بینی قیمت نفت وست تگزاس اینترمدیت و برنت (یو و همکاران، ۲۰۰۸)، پیش‌بینی قیمت جهانی نفت (فرجام‌نیا و همکاران، ۱۳۸۶)، پیش‌بینی قیمت نفت خام نیویورک و خلیج مکزیک (بهرادمهر، ۱۳۸۷)، پیش‌بینی قیمت نفت خام ایران (اصفهانیان، ۱۳۸۲، اصفهانیان و ناصری، ۱۳۸۷) و همچنین پیش‌بینی قیمت بنزین بازار سنگاپور (ابریشمی و همکاران، ۱۳۸۷) از جمله این موارد هستند.

مقایسه توان پیش‌بینی روش شبکه‌عصبی با برخی از روش‌های رگرسیونی و به ویژه روش خودرگرسیون میانگین متحرک در مطالعاتی مانند یو و همکاران (۲۰۰۸)، فرجام‌نیا و همکاران (۱۳۸۶) و همچنین شریف‌النبی (۱۳۸۷) حاکی از برتری شبکه‌عصبی بر خودرگرسیون میانگین متحرک در پیش‌بینی است. البته توانایی بالاتر روش شبکه‌عصبی در پیش‌بینی در مقایسه با روش‌های رگرسیونی به ویژه در خصوص قیمت سهام نیز به طور بارزی مورد تأکید قرار گرفته است که از جمله این مطالعات وو و لو (۱۹۹۳) و اولسون و موس من (۲۰۰۳) می‌باشد.

با توجه به اهمیت قیمت گازوییل به ویژه پس از حذف یارانه آن در اقتصاد ایران این مطالعه با هدف پیش‌بینی قیمت گازوییل بازار سنگاپور به عنوان بازار مؤثر بر قیمت گازوییل در خاورمیانه و یافتن الگوی مناسب برای پیش‌بینی صورت گرفت. ویژگی متمایز مطالعه حاضر در مقایسه با مطالعات مرور شده این است که افزون بر استفاده از الگوهای مختلف شبکه‌عصبی که در اغلب مطالعات تنها برخی از آنها مورد استفاده قرار گرفته است داده‌ها پیش از آموزش شبکه مورد پردازش قرار گرفتند.

1. West Texas Intermediate
2. Autoregressive Conditional Heteroskedasticity


این پردازش شامل تصادفی نمودن قیمت و تفکیک تغییرات به تغییرات مثبت و منفی می‌باشد. استفاده از قیمت نفت‌های تعیین‌کننده وست تگزاس اینترمدیت، برنت و همچنین قیمت گازویل در بازار روتردام در آموزش شبکه از دیگر ویژگی‌های بازار مطالعه حاضر است. یافته‌های مطالعه نیز بهبود در پیش‌بینی‌ها را نسبت به مطالعات مشابه نشان می‌دهند.

ساختار مقاله به این صورت می‌باشد که در بخش بعد مبانی نظری و روش تحقیق ارائه می‌شود که در آن شبکه‌های مورد استفاده و الگوی رگرسیونی خودرگرسیون میانگین متحرک معرفی شده است. در انتهای بخش مبانی نظری و روش تحقیق نیز داده‌های مورد استفاده معرفی شده است. بخش بعد نتایج و بحث می‌باشد که یافته‌های حاصل از پیش‌بینی با استفاده از الگوهای معرفی شده در بخش روش تحقیق را نشان می‌دهد. در پایان نیز یافته‌های مطالعه جمع‌بندی و پیشنهاداتی ارائه شده است.

۲. مبانی نظری و روش تحقیق

۲-۱. مبانی نظری شبکه 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 ساده‌شده‌ای از سیستم عصبی مرکزی می‌باشند. در واقع، شبکه با انجام محاسبات بر داده‌های عددی یا مثال‌ها، قوانین کلی را فرا می‌گیرند و به همین دلیل به آنها سیستم‌های هوشمند گفته می‌شود. یک شبکه عصبی از نرون‌های مصنوعی تشکیل شده است. نرون یا گره کوچکترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد (منهاج، ۱۳۷۷). هر یک از نرون‌ها، ورودی‌ها را دریافت نموده و پس از پردازش بر آنها یک سیگنال خروجی تولید می‌نمایند. لذا هر نرون در شبکه به عنوان مرکز پردازش و توزیع اطلاعات عمل می‌کند و ورودی و خروجی مخصوص به خود را دارد (وو و لو، ۱۹۹۵). شکل (۱) نمایش ساختار یک نرون تک ورودی می‌باشد که در آن اعداد p و a به ترتیب ورودی و خروجی نرون هستند.




شکل ۱. مدل نرون تک ورودی

میزان تأثیر q بر a بوسیله مقدار عدد w تعیین می‌شود. ورودی دیگر مقدار ثابت 1 است که در جمله b ضرب شده و سپس با wp جمع می‌شود. این حاصل جمع ورودی خالص n برای تابع تبدیل یا فعال‌سازی (محرك) f است. به این ترتیب خروجی نرون به صورت معادله (۱) تعریف می‌شود:

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

پارامترهای w و b قابل تنظیم می‌باشند و تابع محرك f نیز توسط طراح انتخاب می‌شود. بر اساس انتخاب f و نوع الگوریتم یادگیری، پارامترهای w و b تنظیم می‌گردند. در حقیقت، یادگیری به این معنا است که w و b به صورتی تغییر کنند که رابطه ورودی و خروجی نرون با هدف خاصی مطابقت نماید. عموماً یک نرون بیش از یک ورودی دارد. در شکل (۲) مدل یک نرون با R ورودی نشان داده شده است.



شکل ۲. مدل چند ورودی یک نرون

در شکل (۲)، عددهای P_i عناصر بردار ورودی می‌باشند و با ماتریس وزن w و جمله اریب (b) ورودی خالص را به صورت رابطه (۲) تشکیل می‌دهند:

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

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 رابطه (۳) خواهد بود:

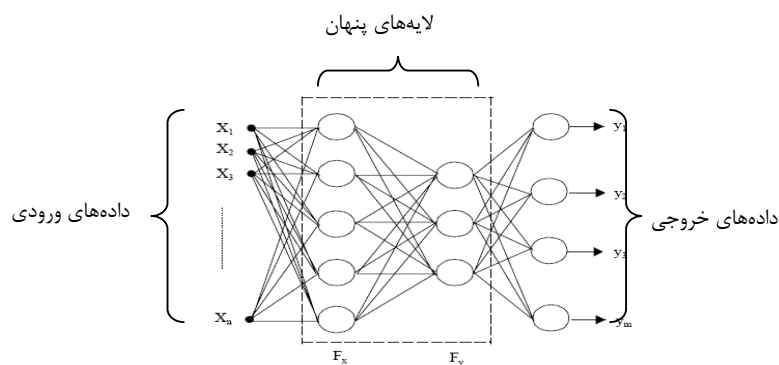
$$a = f(W\bar{P} + b) \quad (3)$$

معمولاً یک نرون حتی با تعداد ورودی‌های زیاد نیز به تنهایی برای حل مسائل کفایت نمی‌کند (منهاج، 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 طرق مختلف سازماندهی شوند به این معنا که نرون‌ها می‌توانند از راه‌های متفاوت به یکدیگر متصل گردند و شبکه‌های عصبی با ساختارهای مختلفی تولید نمایند. در حال حاضر انواع مختلفی از شبکه‌های عصبی وجود دارند که برخی از آنها دارای کاربرد بیشتری هستند. بررسی مطالعات حاکی از تأکید بر استفاده از شبکه‌هایی مانند شبکه پیشخور پس‌انتشار و شبکه آبخاری پس‌انتشار است. به عنوان مثال، کبودان (۲۰۰۱) و همچنین یو و همکاران (۲۰۰۸) شبکه پیشخور پس‌انتشار را پیشنهاد نمودند. مالیک و ناصرالدین (۲۰۰۶) شبکه آبخاری پس‌انتشار را مناسب ارزیابی کردند. شبکه پیشخور پس‌انتشار در مطالعه اصفهانیان (۱۳۸۲) و اصفهانیان و ناصری (۱۳۸۷) نیز مورد تأکید قرار گرفت است. در این مطالعه علاوه بر شبکه‌های یاد شده، دو شبکه رگرسیون تعمیم‌یافته و شبکه المان پس‌انتشار نیز که در برخی از مطالعات همانند اصفهانیان و امین ناصری (۱۳۸۷) مورد توجه قرار گرفته بود استفاده شد که در ادامه معرفی شده‌اند.

۲-۱-۱. شبکه پیشخور پس‌انتشار^۱

در شکل (۳) یک نمونه از شبکه پیشخور پس‌انتشار با دو لایه پنهان نشان داده شده است. در این شبکه هر نرون از لایه‌ها اطلاعات را از نرون‌های لایه قبل دریافت و پس از پردازش آن را به نرون‌های لایه بعد می‌دهد و این فرایند بطور معکوس تکرارپذیر نیست. در شبکه زیر X بردار داده‌های ورودی، Y بردار داده‌های خروجی و F تابع عملگر است که پردازش بر روی داده‌ها را انجام می‌دهد (ایلینا و همکاران، ۲۰۰۴).



شکل ۳. ساختار شبکه پیشخور پس‌انتشار با دو لایه پنهان

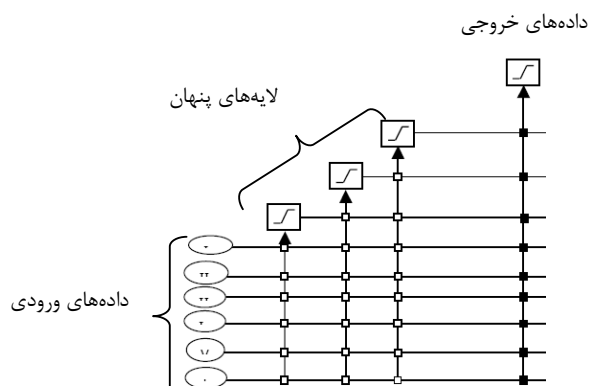
1. Feed forward Back Propagation Network

۲-۱-۲. شبکه المان پس‌انتشار^۱

شبکه المان نیز دارای ساختاری مشابه شبکه پیشخور پس‌انتشار است، اما از لحاظ نوع عملکرد با آن دارای تفاوت است. به این ترتیب که شبکه المان پس‌انتشار بر خلاف شبکه پیشخور پس‌انتشار برگشتی است. در این شبکه در واقع لایه داده‌های ورودی شامل دو قسمت است. قسمت اول داده‌های واقعی را شامل می‌شود و قسمت دوم اطلاعاتی از پردازش داده‌ها توسط لایه پنهان را در خود حفظ می‌کند. به این ترتیب، اطلاعات ایجاد شده توسط یک لایه پنهان مجدداً توسط لایه ورودی مورد استفاده قرار می‌گیرند و از این طریق ادامه فرایند آموزش را تحت تأثیر قرار می‌دهد (هانگ و همکاران، ۲۰۰۵).

۲-۱-۳. شبکه آبخاری پس‌انتشار^۲

در شکل (۴) شبکه آبخاری پس‌انتشار در حالت کلی و برای شبکه حاوی سه لایه پنهان ترسیم شده است. در این شبکه‌ها ابتدا بدون استفاده از نرون‌های لایه پنهان آموزش آغاز شده و شبکه تا پایین‌تر سطح خطای ممکن آموزش را ادامه می‌دهد. سپس یک لایه پنهان با تعدادی نرون به شبکه افزوده شده و آموزش شبکه ادامه می‌یابد و در گام‌های بعدی لایه‌های بعدی افزوده می‌شود (شت، ۲۰۰۴).

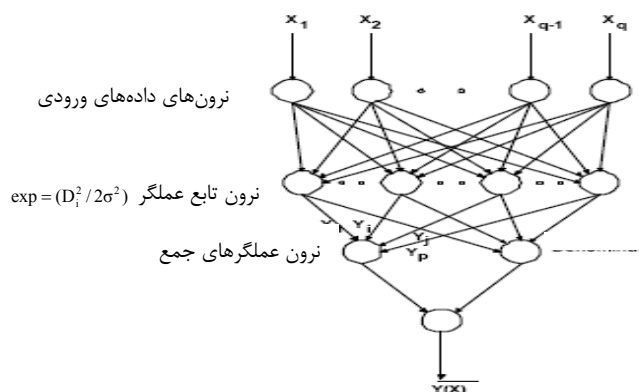


شکل ۴. ساختار شبکه آبخاری پس‌انتشار با سه لایه پنهان

1. Elman Back Propagation Network
2. Cascade Back Propagation Network

۲-۱-۴. شبکه رگرسیون تعمیم یافته^۱

ساختار کلی شبکه رگرسیون تعمیم یافته نیز به صورت زیر است (اسپکت، ۱۹۹۱).



در شبکه رگرسیون تعمیم یافته از توابع زیر استفاده می شود:

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

در روابط فوق، X : بردار داده‌های ورودی، Y : بردار داده‌های خروجی و σ : یک پارامتر است که مقادیر متفاوتی را اختیار می کند. در واقع، رابطه فوق رگرسیون کردن Y بر روی بردار X است. بر اساس این مطالعات استفاده از لایه پنهان فراتر از سه عدد می تواند منجر به انطباق بیش از حد شود (کاسترا و بوید، ۱۹۹۶) لذا در این مطالعه از تعداد لایه‌های ۱، ۲ و ۳ عدد استفاده شد. همچنین با توجه به تأکید مطالعات (رک، ۲۰۰۲) از دو تابع آموزش لوبزگ-مارکوات و شبه نیوتنی^۲ استفاده گردید.

1. Generalize Regression Network

۱. لازم به ذکر است که در ادبیات شبکه عصبی این واژه معادل Quasi Newton (BFG) می باشد.

۲-۲. الگوی خودرگرسیون میانگین متحرک^۱

بطور کلی فرایندی را $ARMA(p, q)$ گویند که شامل p مرتبه جمله خودرگرسیون 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 $ARMA(p, q)$ مدل‌سازی کنیم در این صورت سری زمانی اصلی، سری زمانی خودرگرسیونی میانگین متحرک انباشته $ARIMA(p, d, q)$ می‌باشد (گجراتی، ۱۳۷۸). یک مدل عمومی $ARMA(p, q)$ عبارتست از:

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

۲-۲-۱. انتخاب وقفه در الگوی خودرگرسیون میانگین متحرک

انتخاب وقفه از چالش‌زاترین مراحل پیش‌بینی الگوهای سری زمانی می‌باشد. مارسلینو و همکاران (۲۰۰۶) به منظور انتخاب وقفه در پیش‌بینی سری‌های ماهانه متغیرهای کلان اقتصاد آمریکا با استفاده از الگوی اتورگرسیو^۲ از چهار معیار استفاده نمود که شامل انتخاب وقفه ثابت ۴، انتخاب وقفه ثابت ۱۲، معیار آکائیک و معیار شوارتز^۳ بود. پندک و رابینفلد (۱۹۹۸) استفاده از ضرایب همبستگی جزئی را برای انتخاب وقفه یا مرتبه فرایند اتورگرسیو مناسب عنوان کردند. پسران و پسران (۱۹۹۷) به منظور تعیین وقفه استفاده از معیار آکائیک را پیشنهاد دادند. بر این اساس، آنها استفاده از حداکثر ۳ وقفه را برای پیش‌بینی سالانه مناسب عنوان کردند. در مجموع می‌توان گفت استفاده از بیش از یک معیار و قضاوت نهایی بر اساس خطای پیش‌بینی در اغلب مطالعات مشهودترین نتیجه در ادبیات انتخاب وقفه می‌باشد، اما اندرس (۲۰۰۴) در مقایسه با سایر مطالعات رهنمون جامع‌تری را ارائه کرده است. روش ارائه شده در این رهیافت مبتنی بر ویژگی‌های تابع خود همبستگی (ACF)^۴ و تابع خود همبستگی جزئی (PACF)^۵ است. این روش را در حالت کلی می‌توان به صورت زیر بیان نمود:

- در یک فرایند $ARIMA(p, q)$ تابع خود همبستگی پس از وقفه q محو می‌شود. پس از این وقفه، خود همبستگی کاهش می‌یابد. این کاهش را می‌توان با توجه به ضریب خود همبستگی بررسی نمود.

1. Autoregressive Integrated Moving Average (ARIMA)
2. Autoregressive
3. Schwarz Criterion
4. Autocorrelation Function
5. Partial Autocorrelation Function

- در یک فرایند $ARIMA(p,q)$ تابع خود همبستگی جزئی پس از وقفه 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 اخلاص پس از برآورد فرایند موردنظر و نرمال بودن توزیع این جملات اخلاص استفاده نمود. در این مطالعه، به منظور انتخاب فرایند سری‌های تحت بررسی از روش پیشنهادی اندرس (۲۰۰۴) استفاده گردید. لازم به ذکر است که از وقفه‌های به دست آمده از این روش در شبکه‌های عصبی نیز استفاده گردید. تعیین تعداد وقفه‌های مورد استفاده در شبکه‌های عصبی بر اساس معیار آکائیک در مطالعه مالیک و ناصرالدین (۲۰۰۶) نیز مشاهده می‌شود.

۲-۳. انتخاب بهترین مدل پیش‌بینی

برای تمام روش‌های پیش‌بینی ابتدا می‌بایست داده‌های سری موردنظر را به دو قسمت تقسیم کرد. یک سری از آنها معمولاً برای آموزش یا برازش مدل مورد استفاده قرار می‌گیرند که آنها را اصطلاحاً داده‌های دستگرمی^۱ و سری دوم را که برای آزمون مدل بکار می‌روند را اصطلاحاً نمونه پیش‌بینی^۲ می‌نامند. در این مطالعه داده‌های مورد استفاده برای پیش‌بینی شامل سه گروه ۱۰، ۲۰ و ۳۰ درصد می‌باشد. در واقع، برای تمام مدل‌های پیش‌بینی محاسبات بر مبنای داده‌های دستگرمی انجام می‌شود و به کمک داده‌های دوره پیش‌بینی مورد آزمون قرار می‌گیرند. روش‌های مختلفی برای اندازه‌گیری دقت مدل‌های پیش‌بینی وجود دارد که رایج‌ترین آنها معیار ریشه میانگین مجذور خطاهای پیش‌بینی (RMSE)^۳ است. هر مدلی که کمترین ریشه میانگین مجذور خطاهای پیش‌بینی را داشته باشد به عنوان بهترین مدل پیش‌بینی انتخاب می‌گردد. در این بررسی نیز از معیار یادشده استفاده گردید. این معیار به صورت زیر است (پیندک و رابینفلد، ۱۹۹۸):

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

که در آن، \hat{y}_i و y_i به ترتیب مقادیر پیش‌بینی شده و واقعی سری مورد پیش‌بینی هستند و h نیز تعداد مشاهدات مورد پیش‌بینی می‌باشد. T نیز داده‌های مورد استفاده برای انتخاب فرایند پیش‌بینی یا همان داده‌های دستگرمی می‌باشد. علاوه بر معیار فوق از دو معیار دیگر نیز استفاده شد. این معیارهای

1. Warm up
2. Forecasting Sample
3. Root Mean Squared Error

عبارتند از میانگین مطلق خطاها (MAE)^۱ و معیار درصد میانگین خطاهای پیش‌بینی (MAPE)^۲. مزیت استفاده از شاخص درصد میانگین خطاهای پیش‌بینی این است که وابسته به مقیاس نیست و امکان مقایسه قدرت پیش‌بینی را برای سری‌هایی که دارای مقیاس متفاوت هستند نیز فراهم می‌نماید. این شاخص‌ها به صورت زیر تعریف می‌شوند:

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

هرچه مقادیر این دو شاخص پایین‌تر باشد، پیش‌بینی ارائه‌شده مطلوب‌تر خواهد بود. شاخص میانگین مطلق خطاها نیز به صورت زیر محاسبه می‌شود:

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

همچنین، به منظور مقایسه توان پیش‌بینی شبکه‌های یادشده از آماره دیبلد-ماریانو^۳ به شرح زیر استفاده شد:

$$DM = \bar{d} / \sqrt{\text{var}(\bar{d})} \quad (9)$$

که در آن، \bar{d} میانگین سری تفاضلی تابع خطا در نمونه و $\text{var}(\bar{d})$ نیز واریانس \bar{d} می‌باشد. تابع خطا در حالت معمول بصورت مجذور مقادیر خطای پیش‌بینی در نظر گرفته می‌شود. البته این آماره نیز مبتنی بر فرض عدم همبستگی سریالی مقادیر خطای پیش‌بینی می‌باشد (اندرس، ۲۰۰۴). در این مطالعه نیز از مجذور مقادیر خطا استفاده گردید. مقادیر آماره به دست آمده با مقادیر آماره توزیع نرمال مقایسه می‌گردد و فرض صفر نیز عبارت است از عدم وجود اختلاف معنادار میان پیش‌بینی‌های به دست آمده دو شبکه.

۳. داده‌ها

برای آموزش شبکه‌های عصبی علاوه بر وقفه‌های مختلف قیمت گازوییل سنگاپور از قیمت نفت‌های وست‌تگزاس اینترمدیت و برنت دریای شمال به عنوان نفت‌های مهم (یو و همکاران، ۲۰۰۸) و همچنین

1. Mean Absolute Error
2. Mean Absolute Percentage Error
3. Diebold-Mariano

قیمت گازوییل در بازار روتردام به عنوان مهم‌ترین بازار اروپا (ابریشمی و همکاران، ۱۳۸۷) استفاده شد. پیش از استفاده از داده‌ها نیز پردازشی بر روی آنها صورت 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 شبکه داده‌ها تصادفی شدند. در فرایند تصادفی نمودن ابتدا مقادیر سری تصادفی در محیط نرم افزار اکسل و متناظر با سری قیمت گازوییل ایجاد و سپس بر اساس سری تصادفی اعداد مرتب گردید.^۱

داده‌های مورد استفاده قیمت‌های هفتگی نفت خام ایران شامل دوره ابتدای ژانویه ۱۹۸۷ تا انتهای مارس ۲۰۱۰ یعنی ۱۱۹۰ مشاهده می‌باشد. این داده‌ها در قالب سه رویکرد مجزا برای پیش‌بینی مورد استفاده قرار گرفتند. به این ترتیب که در رویکرد اول ۹۰ درصد از داده‌ها برای آموزش (تخمین) و ۱۰ درصد باقیمانده برای پیش‌بینی مورد استفاده قرار گرفت. در دو رویکرد دیگر نسبت‌های یاد شده به ترتیب (۸۰-۲۰) و (۷۰-۳۰) بود. داده‌های مورد استفاده از پایگاه اطلاعاتی سازمان مدیریت اطلاعات انرژی ایالات متحده به دست آمد. برای آموزش و پیش‌بینی شبکه‌های عصبی مصنوعی نیز از نرم‌افزار Matlab7.1 استفاده شد. تخمین الگوی رگرسیونی خودرگرسیون میانگین متحرک نیز با استفاده از نرم‌افزار Eviews5 صورت گرفت.

۴. نتایج و بحث

به منظور تخمین الگوی رگرسیونی خودرگرسیون میانگین متحرک ابتدا ایستایی داده‌ها بررسی گردید. نتایج آزمون ایستایی نشان دادند که این داده‌ها در سطح ایستا نمی‌باشند، اما پس از یک‌بار تفاضل‌گیری رفتاری ایستا نشان دادند. یافته‌های مطالعه در دو قالب ارائه شده است. ابتدا خطای پیش‌بینی برای هر یک از شبکه‌ها آمده است و در ادامه، خطای پیش‌بینی شبکه دارای کمترین خطای پیش‌بینی ارائه شده است. در جداول (۴)-(۱) نیز خلاصه یافته‌های پیش‌بینی قیمت گازوییل در بازار سنگاپور ارائه شده است. لازم به ذکر است که مقادیر ذکر شده در جدول (۱) تنها معیار درصد میانگین خطاهای پیش‌بینی است که خطای پیش‌بینی را بر حسب درصد نشان می‌دهد.

همان‌طور که در این جدول نیز مشاهده می‌شود، در مورد شبکه‌های مورد استفاده برای پیش‌بینی ۱۰ درصد داده‌ها میان نتایج شبکه پیشخور پس‌انتشار و شبکه آبشاری پس‌انتشار تشابه بیشتری وجود

۱. لازم به ذکر است که در محیط Excel از دستور Rand () برای این منظور استفاده می‌شود.

دارد. در هر دو این شبکه‌ها استفاده از تابع آموزش شبه نیوتنی موجب شده است تا شبکه نسبت به تعداد لایه پنهان هیچ حساسیتی نداشته باشد. اما با بکارگیری تابع آموزش لونیبرگ-مارکوات اهمیت تعداد لایه پنهان بطور روشن مشاهده می‌شود. در این دو شبکه دقیق‌ترین پیش‌بینی با استفاده از شبکه دارای یک لایه پنهان حاصل شده است و شبکه دارای دو لایه پنهان خطای بیشتری در پیش‌بینی داشته است. در خصوص پیش‌بینی‌های حاصل از شبکه المان پس‌انتشار به نظر می‌رسد استفاده از یک یا سه لایه پنهان موجب کاهش دقت پیش‌بینی می‌شود که با استفاده از تابع آموزش شبه‌نیوتنی با یک لایه پنهان خطای پیش‌بینی بطور نامطلوبی افزایش می‌یابد. البته استفاده از تابع آموزش لونیبرگ-مارکوات موجب بهبود پیش‌بینی‌های نسبت به شبکه‌های مبتنی بر تابع آموزش شبه‌نیوتنی شده است اما استفاده از سه لایه پنهان تحت تأثیر نوع تابع آموزش قرار نمی‌گیرد. شبکه رگرسیون تعمیم‌یافته نیز تنها از الگوی رگرسیونی خودرگرسیون میانگین متحرک پیش‌بینی‌های بهتری دارد. برای پیش‌بینی ۱۰ درصد از داده‌ها می‌توان با استفاده از شبکه پیشخور پس‌انتشار با خطای کمتر از ۲ درصد پیش‌بینی ارائه نمود. این رقم برای شبکه آبخاری پس‌انتشار، شبکه المان پس‌انتشار و شبکه رگرسیون تعمیم‌یافته ۲/۵-۲ درصد است.

یافته‌های به دست آمده برای شبکه‌هایی که مبادرت به پیش‌بینی ۲۰ درصد از داده‌ها نموده‌اند نیز دارای روندهای مشهود می‌باشد. در این شبکه‌ها که دارای تنوع در تابع آموزش و تعداد لایه‌های پنهان می‌باشد یعنی در شبکه‌های پیشخور پس‌انتشار، آبخاری پس‌انتشار و المان پس‌انتشار استفاده از تابع آموزش شبه‌نیوتنی به معنای حذف نقش لایه‌های پنهان بوده است و همان‌طور که در جدول (۱) نیز مشخص شده است به دنبال استفاده از تابع آموزش شبه‌نیوتنی اثر تعداد لایه‌های پنهان بسیار نامحسوس ظاهر شده است. برخلاف آنچه در مورد اثر تعداد لایه پنهان بر دقت پیش‌بینی در شبکه‌های تحت آموزش شبه‌نیوتنی گفته شد در شبکه‌هایی که از تابع آموزش لونیبرگ-مارکوات بهره گرفته‌اند اثر مشخصی از آنها مشاهده می‌شود. به این ترتیب که در هر سه گروه از شبکه‌های یادشده استفاده از سه لایه پنهان کمترین خطای پیش‌بینی را به همراه داشته است و از سوی دیگر، دو لایه پنهان بالاترین خطا را موجب شده است. همانند شبکه‌های مورد استفاده پیش‌بینی‌های ارائه شده برای ۲۰ درصد از داده‌های قیمت گازوییل توسط شبکه رگرسیون تعمیم‌یافته و الگوی رگرسیونی خودرگرسیون میانگین متحرک در اولویت‌های بعدی قرار دارد. استفاده از ۸۰ درصد داده‌ها برای آموزش و پیش‌بینی ۲۰ درصد باقیمانده در مقایسه با شرایطی که ۱۰ درصد برای پیش‌بینی کنار گذاشته شد با کاهش خطای پیش‌بینی در تمام الگوها همراه شده است.

نتایج به دست آمده برای پیش‌بینی ۳۰ درصد از داده‌ها روند منظمی از اثرگذاری تعداد لایه پنهان و نوع تابع آموزش را نشان نمی‌دهد و در هر یک از شبکه‌ها اثر یکی از آنها بارزتر بوده است. به عنوان مثال، در مورد شبکه پیشخور پس‌انتشار اثر نوع تابع آموزش حائز اهمیت است، اما در مورد شبکه آبخاری پس‌انتشار استفاده از یک لایه پنهان تقریباً فارغ از نوع تابع آموزش دارای کمترین خطای پیش‌بینی است. همچنین، در مورد نتایج شبکه المان پس‌انتشار هیچ یک از استنباط‌های فوق قابل استخراج نیست. در مورد شبکه رگرسیون تعمیم‌یافته افزایش استفاده از سهم داده‌های پیش‌بینی موجب افزایش خطای پیش‌بینی شده است در حالی که در مورد الگوی خودرگرسیون میانگین متحرک عکس آن مشاهده می‌شود.

جدول ۱. درصد خطای پیش‌بینی حاصل از پیش‌بینی قیمت گازوییل در بازار سنگاپور با استفاده از الگوهای مختلف

نوع الگو	تعداد لایه‌های پنهان						نوع تابع آموزش
	شبه‌نیوتنی			لونبرگ-مارکوات			
	۳	۲	۱	۳	۲	۱	درصد داده‌های پیش‌بینی
شبکه پیشخور پس‌انتشار	۲/۶۳	۲/۶۳	۲/۶۳	۲/۴۵	۳/۰۳	۱/۹۹	۱۰
	۲/۵۸	۲/۵۸	۲/۵۸	۱/۸۷	۲/۶۹	۱/۹۴	۲۰
	۲/۵۸	۲/۵۸	۲/۵۸	۲/۲۷	۲/۰۵	۲/۵۱	۳۰
شبکه آبخاری پس‌انتشار	۲/۰۳	۲/۰۶	۲/۰۵	۲/۱۸	۲/۲۱	۲/۱۲	۱۰
	۲/۰۳	۲/۰۸	۲/۰۸	۲/۱۱	۲/۶۲	۲/۱۷	۲۰
	۳/۷۴	۲/۴۳	۲/۰۱	۲/۳۱	۲/۲۱	۲/۰۴	۳۰
شبکه المان پس‌انتشار	۲/۶۳	۲/۶۳	۳۰/۰۸	۲/۶۳	۲/۳۱	۲/۴۶	۱۰
	۲/۶۲	۲/۵۸	۲/۵۸	۱/۹۲	۲/۴۴	۲/۳۶	۲۰
	۲/۵۸	۲/۵۸	۳/۲۳	۲/۰۱	۳	۲/۳۴	۳۰
شبکه رگرسیون تعمیم‌یافته			۲/۷۸				۱۰
			۲/۶۷				۲۰
			۲/۸۵				۳۰
الگوی خودرگرسیون میانگین متحرک			۳/۹۸				۱۰
			۳/۱۳				۲۰
			۲/۹۷				۳۰

مأخذ: نتایج تحقیق.

در جداول (۴) - (۲) نیز الگوهای دارای کمترین خطا برای هر یک از سه گروه از داده‌ها ارائه شده است. برای پیش‌بینی ۱۰ درصد داده‌ها به نظر می‌رسد پیکربندی شبکه با استفاده از دو امکان تابع آموزش و لایه پنهان موجب دستیابی به پیش‌بینی‌هایی با خطای کمتر شده است و شبکه‌های دارای این موقعیت کمترین خطای پیش‌بینی را داشته‌اند (جدول ۲). البته تمایز میان توابع آموزش دشوار است زیرا شبکه دارای کمترین خطای پیش‌بینی از تابع آموزش لونبرگ-مارکوات استفاده کرده است شبکه دارای رتبه دوم از تابع آموزش شبه نیوتنی و مجدداً در شبکه المان پس‌انتشار استفاده از تابع آموزش لونبرگ-مارکوات کمترین خطا را به همراه داشته است، لذا اهمیت تابع آموزش در کنار نوع شبکه قابل ملاحظه خواهد بود. در مورد تعداد لایه پنهان نیز به راحتی نمی‌توان استدلال روشنی ارائه نمود اما بطور کلی در خصوص داده‌های ۱۰ درصد تمایل به استفاده از تعداد لایه کمتر بوده است. دو الگوی دیگر در مقایسه با شبکه‌های یادشده خطای بالاتری دارند.

جدول ۲. نتایج حاصل از پیش‌بینی قیمت گازوییل بازار سنگاپور از طریق الگوهای مختلف با استفاده از ۱۰ درصد داده‌ها

نوع الگو	شبکه پیشخور	شبکه آبخاری	شبکه المان	شبکه رگرسیون الگوی خودرگرسیون	ویژگی‌ها
	پس‌انتشار	پس‌انتشار	پس‌انتشار	تعمیم‌یافته	میانگین متحرک
نوع تابع آموزش	لونبرگ-مارکوات	شبه‌نیوتنی	لونبرگ-مارکوات	-	-
تعداد لایه‌های پنهان	۱	۱	۲	-	-
ریشه میانگین مجذور	۲/۷۱	۲/۹۶	۳/۱۵	۴/۹۹	۱۱/۷۷
خطاهای پیش‌بینی	۱/۸۱	۱/۸۹	۲/۱۱	۲/۸۸	۸/۶۲
میانگین مطلق خطاها	۱/۹۹	۲/۰۵	۲/۳۱	۲/۷۸	۳/۹۸
درصد میانگین	۹۴/۴۳	۹۴/۴۵	۹۴/۵۲	۹۴/۴۹	۲۲۳/۲
خطاهای پیش‌بینی	۱	۲	۳	۴	۵
میانگین (۹۴/۷۰)					
رتبه					

مأخذ: نتایج تحقیق.

در جدول (۳) یافته‌های به دست آمده برای ۲۰ درصد از داده‌ها ارائه شده است. در این جدول کم‌خطاترین تابع آموزش برای هر یک از انواع شبکه‌ها همانند جدول (۲) است، اما تفاوت دیگر در اولویت شبکه‌ها است. به این ترتیب که در این گروه از پیش‌بینی‌ها دو شبکه دارای کمترین خطای پیش‌بینی که به ترتیب شبکه المان پس‌انتشار و شبکه پیشخور پس‌انتشار هستند هر دو از تابع آموزش

لونبرگ- مارکوات استفاده کرده‌اند و شبکه آبخاری پس‌انتشار که در رتبه سوم قرار دارد از تابع آموزش شبه‌نیوتنی برای آموزش شبکه بهره گرفته است. بطور قطع می‌توان گفت شبکه‌هایی که از تابع آموزش لونبرگ- مارکوات استفاده می‌کنند از خطای پیش‌بینی کمتر از ۲ درصد برخوردار خواهند بود. در مورد شبکه آبخاری پس‌انتشار که از تابع آموزش شبه‌نیوتنی استفاده می‌کند این رقم اندکی بالاتر از ۲ درصد است. این رقم در خصوص شبکه رگرسیون تعمیم‌یافته و الگوی رگرسیونی خودرگرسیون میانگین متحرک نیز به ترتیب بیش از ۲/۵ و بیش از ۳ درصد است. در مورد شبکه‌های به دست آمده برای پیش‌بینی ۲۰ درصد از داده‌ها تابع آموزش لونبرگ- مارکوات تمایل به استفاده از تعداد لایه پنهان بالا دارد.

جدول ۳. نتایج حاصل از پیش‌بینی قیمت گازوییل بازار سنگاپور از طریق الگوهای مختلف با استفاده از ۲۰ درصد داده‌ها

نوع الگو	شبکه پیشخور	شبکه آبخاری	شبکه المان	شبکه رگرسیون	الگوی خودرگرسیون
ویژگی‌ها	پس‌انتشار	پس‌انتشار	پس‌انتشار	تعمیم‌یافته	میانگین متحرک
نوع تابع آموزش	لونبرگ- مارکوات	شبه نیوتنی	لونبرگ- مارکوات	-	-
تعداد لایه‌های پنهان	۳	۱	۳	-	-
ریشه میانگین مجذور خطاهای پیش‌بینی	۲/۸۷	۲/۸۷	۲/۶۱	۴/۷۵	۹/۱۲
میانگین مطلق خطاها	۱/۷۷	۱/۹۳	۱/۷۶	۲/۷۶	۶/۴۰
درصد میانگین خطاهای پیش‌بینی	۱/۸۷	۲/۰۸	۱/۹۲	۲/۶۷	۳/۱۳
میانگین (۹۷/۷۲)	۹۷/۵۷	۹۷/۷۶	۹۷/۶۵	۹۸/۰۸	۲۰۴/۵
رتبه	۲	۳	۱	۴	۵

مأخذ: نتایج تحقیق.

در جدول (۴) نیز یافته‌های مشابه برای ۳۰ درصد از داده‌ها ارائه شده است. در این جدول نیز شبکه پیشخور پس‌انتشار و شبکه المان پس‌انتشار از تابع آموزش لونبرگ - مارکوات استفاده نمودند و همچنین شبکه آبخاری پس‌انتشار تابع آموزش شبه‌نیوتنی را ترجیح داده است. البته از لحاظ

خطای پیش‌بینی سه الگوی یادشده اختلاف کمی با یکدیگر دارند. بر اساس نتایج به دست آمده در جدول (۴) برحسب نوع تابع آموزش و همچنین تعداد لایه پنهان نمی توان میان شبکه‌ها تمایزی قائل شد. در مورد شبکه‌های بکار گرفته شده برای پیش‌بینی ۳۰ درصد از داده‌ها الگوی خودرگرسیون میانگین متحرک در مقایسه با آنچه پیشتر برای پیش‌بینی ۱۰ و ۲۰ درصد داده‌ها مشاهده شد عملکرد خود را بهبود بخشیده است و اختلاف میان آن با شبکه رگرسیون تعمیم‌یافته بسیار اندک می‌باشد. در مورد هر سه گروه از داده‌ها بر حسب مقادیر میانگین میان پیش‌بینی‌ها و میانگین سری حقیقی تفاوت بسیار اندکی دیده می‌شود.

جدول ۴. نتایج حاصل از پیش‌بینی قیمت گازوییل بازار سنگاپور از طریق الگوهای مختلف با استفاده از ۳۰ درصد داده‌ها

نوع الگو ویژگی‌ها	شبکه پیشخور پس‌انتشار	شبکه آبخاری پس‌انتشار	شبکه المان پس‌انتشار	شبکه رگرسیون تعمیم‌یافته	شبکه رگرسیون میانگین متحرک
نوع تابع آموزش	لونیبرگ- مارکوآت	شبه‌نیوتنی	لونیبرگ- مارکوآت	-	-
تعداد لایه‌های پنهان	۲	۱	۳	-	-
ریشه میانگین مجذور خطاهای پیش‌بینی	۲/۹۴	۲/۸۳	۲/۷۲	۴/۵۸	۷/۸۳
میانگین مطلق خطاها	۱/۸۶	۱/۸۳	۱/۷۹	۲/۷۵	۵/۲۸
درصد میانگین خطاهای پیش‌بینی	۲/۰۵	۲/۰۱	۲/۰۱	۲/۸۵	۲/۹۷
میانگین (۹۴/۱۱)	۹۳/۹۱	۹۴/۰۹	۹۴	۹۴/۳۲	۱۷۲/۵
رتبه	۳	۲	۱	۴	۵

مأخذ: نتایج تحقیق.

در جدول (۵) مقادیر آماره دیبلد- ماریانو جهت ارزیابی و مقایسه پیش‌بینی‌های به دست آمده از شبکه‌های مختلف ارائه شده است. در این آماره مقادیر مجذور خطاهای پیش‌بینی مورد استفاده قرار گرفته است. با توجه به اینکه داده‌ها به صورت تصادفی درآمده و سپس در پیش‌بینی مورد استفاده قرار گرفته است، لذا این آماره تنها برای شبکه‌های عصبی قابل استفاده است. مقادیر آماره یادشده تنها برای شبکه‌های ارائه شده در جداول (۴)-(۲) ارائه شده است. همان‌طور که مشاهده می‌شود مقادیر آماره دیبلد- ماریانو در سطح پایینی قرار دارد و می‌توان گفت شبکه‌های ارائه شده در جداول (۴) - (۲) از لحاظ آماری تفاوتی در توان پیش‌بینی با یکدیگر ندارند. البته در این خصوص لازم به ذکر است

همان‌طور که اندرس (۲۰۰۴) نیز عنوان نموده است این آماره‌ها مبتنی بر فروض خاص می‌باشد و در استفاده از آنها به عنوان معیار قضاوت لازم است جانب احتیاط نیز رعایت شود.

جدول ۵. مقادیر آماره دبیلد- ماریانو برای شبکه‌های بررسی شده

درصد داده‌های پیش‌بینی	۱۰	۲۰	۳۰
پیشخور پس انتشار	-		
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		
پیشخور پس انتشار			
آبشاری پس انتشار	-۰/۰۸		
المان پس انتشار	-۰/۱۱		
رگرسیون تعمیم یافته	-۰/۲۷		

مأخذ: نتایج تحقیق.

۵. نتیجه‌گیری و پیشنهادات

اهمیت منابع انرژی در اقتصادها باعث شده است تا تغییرات قیمت آن همواره مورد توجه و تأکید باشد به ویژه با ظهور روش‌های توانمند همانند شبکه‌عصبی مصنوعی تمایل به پیش‌بینی روند آتی قیمت‌های این منابع بیشتر شده است. البته عمدتاً نفت خام مورد توجه بوده است، اما همان‌طور که در ابتدای مطالعه

نیز ذکر شد در مورد قیمت گازوییل در بازار سنگاپور که به عنوان متغیر بیانگر قیمت گازوییل در بازار خاورمیانه مورد استفاده قرار گرفته است الگوی نوسان با نفت خام متفاوت است. اما علیرغم این تفاوت و همچنین نقش حائز اهمیت آن در اقتصاد ایران در مطالعات به آن توجهی نشده است. با توجه به اینکه افق مورد استفاده در آموزش و پیش‌بینی در این مطالعات با مطالعات گذشته تفاوت دارد لذا امکان مقایسه خطای پیش‌بینی تنها با مطالعاتی وجود دارد که خطای پیش‌بینی را بر حسب درصد بیان نموده‌اند. در میان مطالعات داخلی در دسترس تنها مطالعه اصفهانیان و امین ناصری (۱۳۸۷) دارای چنین ویژگی بود که در آن مطالعه خطای پیش‌بینی در شبکه دارای کمترین خطا ۳/۴۸ درصد به دست آمد. در حالی که در مطالعه حاضر برای پیش‌بینی هر سه گروه ۱۰، ۲۰ و ۳۰ درصد این رقم تنها حدود ۲ درصد به دست آمده است. به این ترتیب استفاده از شبکه‌های پیشنهادی مطالعه می‌تواند بطور قابل توجهی موجب بهبود پیش‌بینی‌ها شود. همچنین، همانند مطالعات یو و همکاران (۲۰۰۸)، فرجام‌نیا و همکاران (۱۳۸۶) و شریف‌النبی (۱۳۸۷) برتری پیش‌بینی‌های شبکه عصبی بر خودرگرسیون میانگین متحرک مشخص گردید.

در مورد تمام داده‌ها کمترین خطای پیش‌بینی در شبکه‌ای حاصل شده است که از تابع آموزش لونبرگ-مارکوات استفاده می‌کند. علاوه بر این، مشخص شد در اغلب موارد استفاده از تابع آموزش شبه‌نیوتنی منجر به عدم حساسیت شبکه نسبت به تعداد لایه‌های پنهان می‌شود، لذا بهتر است در مطالعات بر استفاده از تابع آموزش لونبرگ-مارکوات تأکید بیشتری ورزیده شود.

در مورد تمام گروه از داده‌ها دو شبکه پیشخور پس‌انتشار و شبکه المان پس‌انتشار از تابع آموزش لونبرگ-مارکوات و شبکه آبخاری پس‌انتشار از تابع آموزش شبه‌نیوتنی استفاده می‌کند و این می‌تواند موجب صرفه‌جویی در دستیابی به نتایج مطلوب شود.

شبکه‌های دارای تابع آموزش شبه‌نیوتنی تمایل به استفاده از تعداد لایه پنهان کمتر دارند لذا بهتر است در صورت استفاده از این تابع آموزش از لایه‌های پنهان کمتری استفاده شود، اما در مورد شبکه‌هایی که از تابع آموزش لونبرگ-مارکوات استفاده می‌کنند روند منظمی در تعداد لایه‌های پنهان دیده نمی‌شود.

در مورد هیچ گروهی از داده‌ها شبکه رگرسیون تعمیم‌یافته و الگوی رگرسیونی خودرگرسیون میانگین متحرک در مقایسه با سه شبکه دیگر از دقت قابل رقابت برخوردار نبودند. لذا استفاده این الگوها توصیه نمی‌شود.

به‌طور نسبی استفاده از ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای پیش‌بینی در مقایسه با سایر ترکیب از داده‌ها خطای پیش‌بینی کمتر به دنبال دارد لذا می‌توان ترکیب ۸۰-۲۰ درصد را به عنوان ترکیب مطلوب برای پیش‌بینی‌های قیمت گازویل پیشنهاد نمود.

منابع

- ابریشمی، حمید. معینی، علی، مهرآرا، محسن، احراری، مهدی و فاطمه سلیمانی کیا (۱۳۸۶)، "مدلسازی و پیش‌بینی قیمت بنزین با استفاده از شبکه عصبی GMDH"، فصلنامه پژوهش‌های اقتصادی ایران، سال ۱۲، شماره ۳۶، صص ۳۷-۵۸.
- ابریشمی، حمید، مهرآرا، محسن و یاسمین آریانا (۱۳۸۷)، "ارزیابی عملکرد مدل‌های پیش‌بینی بی‌ثباتی قیمت نفت"، مجله تحقیقات اقتصادی، شماره ۷۸، صص ۲۱-۱.
- اصفهانیان، مجید (۱۳۸۲)، ارائه یک مدل شبکه عصبی جهت پیش‌بینی قیمت نفت خام، پایان‌نامه کارشناسی ارشد، گروه مهندسی صنایع، دانشگاه تربیت مدرس.
- اصفهانیان مجید و محمدرضا امین‌ناصری (۱۳۸۷)، "ارائه یک مدل شبکه عصبی جهت پیش‌بینی کوتاه‌مدت قیمت نفت خام"، ویژه‌نامه مهندسی صنایع، شماره ۱، جلد ۱۹، صص ۳۵-۲۷.
- بهراد مهر، نفیسه (۱۳۸۷)، "پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و شبکه عصبی مصنوعی"، فصلنامه مطالعات اقتصاد انرژی، سال ۵، شماره ۱۸، صص ۹۸-۸۱.
- شریف‌النبی، مصطفی (۱۳۷۸)، کاربرد شبکه‌های عصبی در پیش‌بینی: مطالعه موردی پیش‌بینی قیمت نفت، پایان‌نامه کارشناسی ارشد، گروه مدیریت، دانشگاه شیراز.
- فرجام‌نیا، ایمان، ناصری، محسن و سیدمحمد مهدی احمدی (۱۳۸۶)، "پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی"، فصلنامه پژوهش‌های اقتصادی ایران، سال ۹، شماره ۳۲، صص ۱۸۳-۱۶۱.
- گجراتی، دامودار (۱۳۷۸)، مبانی اقتصادسنجی، ترجمه حمید ابریشمی، جلد دوم، تهران: انتشارات دانشگاه تهران.
- منهاج، محمد باقر (۱۳۷۷)، مبانی شبکه‌های عصبی (هوش محاسباتی)، تهران: نشر دکتر حسابی.
- Enderse, W. (2004), *Applied Econometrics Time Series*, John Wiley and Sons, Inc.
- Huang, W., Nakamori, Y. & S.Y. Wang (2005), "Forecasting Stock Market Movement Direction with Support Vector Machine", *Computers and Operations Research*, Vol. 32, PP. 2513-2522.
- Ileana, I., Rotar, C. & A. Incze (2004), "The Optimization of Feed Forward Neural Networks Structure Using Genetic Algorithms", *International Conference on Theory and Applications of Mathematics and Informatics*, Thessaloniki, Greece, PP. 223-234.
- Kaastra, I. & M. Boyd (1996), "Designing a Neural Network for Forecasting Financial and Economic Time Series", *Neurocomputing*, Vol. 10, PP. 215-236.

- Kaboudan, M. A.** (2001), *Compumetric Forecasting of Crude Oil Price*, IEEE, PP. 283-287.
- Kang, S. H., Kang, S. M. & S.M. Yoon** (2009), "Forecasting Volatility of Crude Oil Markets", *Energy Economics*, Vol. 31, PP. 119-125
- Lanza, A., Manera, M. & M. Giovannini** (2005), "Modeling and Forecasting Cointegrated Relationships among Heavy Oil and Product Prices", *Energy Economics*, Vol. 27, PP. 831- 848.
- Malik, F. & M. Nasereddin** (2006), "Forecasting Output Using Oil Prices: A Cascaded Artificial Neural Network Approach", *Journal of Economics and Business*, Vol. 58, PP. 168-180.
- Marcellino, M., Stock, J. H. & M.W. Watson** (2006), "A Comparison of Direct and Indirect and Iterated Multi Step AR Methods for Forecasting Macroeconomic Time Series", *Journal of Econometrics*, Vol. 135, PP. 499-526.
- Morana, C.** (2001), "A Semi Parametric Approach to Short-Term Oil Price Forecasting", *Energy Economics*, Vol. 23, PP. 325-338.
- Olson, D. & C. Mossman** (2003), "Neural Network of Canadian Stock Returns Using Accounting Ratios", *International Journal of Forecasting*, Vol. 19, PP. 453-465.
- Pesaran, H.M. & B. Pesaran** (1994), " Working With Microfit 4.0: An Introduction to Econometrics", Oxford: Oxford University Press.
- Pindyck, R. S. & D.L. Rubinfeld** (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, PP. 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, PP. 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, S. I. & R.P. Lu** (1995), "Combining Artificial Neural Networks and Statistics for Stock-Market Forecasting", PP. 257-264.
- Yu, L., Wang, S. & K.K. Lai** (2008), "Forecasting Crude Oil Price with an EMD-Based Neural Network Ensemble Learning Paradigm", *Energy Economics*, Vol. 30, PP. 2623-2635.

