

## معرفی الگوهای مناسب پیش‌بینی قیمت گازویل

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 گازویل در بازار انرژی سنگاپور به عنوان بازار مؤثر بر قیمت گازویل 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 شبکه‌عصی و یک الگوی رگرسیونی (خودرگرسیون میانگین متحرک) بود. شبکه‌های منتخب شامل شبکه پیشخور پس انتشار، شبکه آبشاری پس انتشار، شبکه المان پس انتشار و شبکه رگرسیون تعمیم‌یافته می‌باشد. همچنین، توابع آموزش مورد استفاده در پیش‌بینی شامل توابع لونبرگ-مارکوآت و شبکه‌یوتی است. یافته‌ها در مورد تمام گروه از داده‌ها، کمترین خطای پیش‌بینی در شبکه را نشان دادند که از تابع آموزش لونبرگ-مارکوآت استفاده می‌کند. همچنین، مشخص شد برای پیش‌بینی ۲۰ و ۳۰ درصد داده‌ها شبکه المان پس انتشار و برای پیش‌بینی ۱۰ درصد داده‌ها شبکه پیشخور پس انتشار 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 گازویل 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 گازویل، شبکه عصی 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 تزدیک گازویل با نفت خام شرایط این محصول از شرایط بازار نفت بطور کامل متأثر می‌گردد. نفت خام در برخی از موقع 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 (۱۹۹۷-۲۰۱۰) برابر با ۱۶ می‌باشد، اما این ضریب در دوره یادشده برای قیمت گازویل در بازار سنگاپور به عنوان بازار تأثیرگذار بر بازار گازویل خاورمیانه بیش از ۴۷ است (سازمان مدیریت اطلاعات انرژی ایالات متحده، ۲۰۱۰). این رقم حاکی از نوسان‌های گسترده‌تر در بازار گازویل می‌باشد. با توجه به گستردگی استفاده از گازویل در بخش تولید به ویژه در بخش‌های آسیب‌پذیر و زیربنایی مانند حمل و نقل، نوسان قیمت آن می‌تواند آثار مستقیم و غیرمستقیم قابل ملاحظه‌ای داشته باشد.

در ایران گازویل به صورت یارانه‌ای و توسط دولت توزیع می‌شود، اما با توجه به تلاش دولت در جهت حذف یارانه گازویل در آینده تغییرات قیمت آن نیز باید بیش از گذشته به منظور دستیابی به اهداف برنامه‌های اقتصادی موردنظر 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 گازویل از قیمت گازویل در بازار سنگاپور استفاده شده است. برای مقابله با شرایط پر نوسان قیمت گازویل علاوه بر تلاش در جهت یافتن جایگزین‌هایی برای نقش‌های ایفا کی این منبع انرژی که البته یک راه حل بلندمدت است. تلاش در جهت شناخت بیشتر رفشار آنها نیز می‌تواند به عنوان یک ابزار مهم به ویژه در کوتاه‌مدت موردنظر سیاست‌گذاران قرار گیرد. این شناخت رفشار می‌تواند آنها را در جهت پیش‌بینی رفتار مساعده نماید. امروزه ابزارهای مناسبی برای این منظور در دسترس است که می‌توانند پیش‌بینی‌های مطلوبی ارائه نمایند.

در خصوص پیش‌بینی قیمت انرژی عمده‌ای قیمت نفت موردنظر بوده است. این در حالی است که الگوی نوسان فرآورده‌های آن همچون گازویل 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

رگرسیونی 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 و سنت تگزاس اینترمدیت<sup>۱</sup> توسط ابریشمی و همکاران (۱۳۸۶) از جمله این مطالعات هستند. نکته حائز اهمیت در این مطالعات، وجود ویژگی موسم به اثر خودرگرسیون با واریانس ناهمسانی شرطی<sup>۲</sup> است که امکان بیان رفتار نوسان قیمت نفت را فراهم نموده است. هرچند وجود نوسان گسترده امکان استفاده از چنین الگوی رگرسیونی را محدود 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 و سنت تگزاس اینترمدیت و برنت (یو و همکاران، ۲۰۰۸)، پیش‌بینی قیمت جهانی نفت (فرجام‌نیا و همکاران، ۱۳۸۶)، پیش‌بینی قیمت نفت خام نیویورک و خلیج مکزیک (بهراهم‌هر، ۱۳۸۷)، پیش‌بینی قیمت نفت خام ایران (اصفهانیان، ۱۳۸۲، اصفهانیان و ناصری، ۱۳۸۷) و همچنین پیش‌بینی قیمت بتزین بازار سنگاپور (ابریشمی و همکاران، ۱۳۸۷) از جمله این موارد هستند.

مقایسه توان پیش‌بینی روش شبکه عصبی 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 شریف‌النی (۱۳۸۷) حاکی از برتری شبکه عصبی بر خودرگرسیون میانگین متحرک در پیش‌بینی است. البته توانایی بالاتر روش شبکه عصبی در پیش‌بینی در مقایسه با روش‌های رگرسیونی به ویژه در خصوصی 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 گازویل به ویژه پس از حذف یارانه آن در اقتصاد ایران این مطالعه با هدف پیش‌بینی قیمت گازویل بازار سنگاپور به عنوان بازار مؤثر بر قیمت گازویل 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 شبکه عصبی که در اغلب مطالعات تنها برخی از آنها مورداً استفاده قرار گرفته است داده‌ها پیش از آموزش شبکه عصبی مورد پردازش قرار گرفتند.

1. West Texas Intermediate

2. Autoregressive Conditional Heteroskedasticity

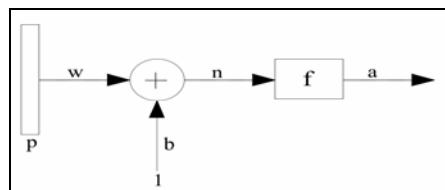
این پردازش شامل تصادفی نمودن قیمت و تفکیک تغییرات به تغییرات مثبت و منفی می‌باشد. استفاده از قیمت نفت‌های تعیین‌کننده وست تگراس ایترمیدیت، برنت و همچنین قیمت گازویل در بازار روتردام در آموزش شبکه از دیگر ویژگی‌های بازار مطالعه حاضر است. یافته‌های مطالعه نیز بهبود در پیش‌بینی‌ها را نسبت به مطالعات مشابه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

### ۱-۲. مبانی نظری شبکه عصبی مصنوعی<sup>۱</sup>

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 سیگнал 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.

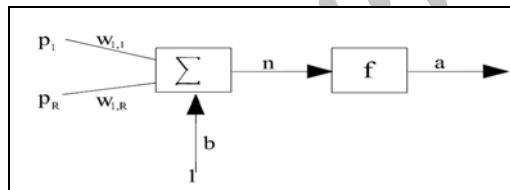


شکل ۱. مدل نرون تک ورودی

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  $n$  برایتابع 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)، عده‌های  $P_i$  عناصر بردار ورودی می‌باشند و با ماتریس وزن  $W$  و جمله اریب (b) ورودی خالص را به صورت رابطه (۲) تشکیل می‌دهند:

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

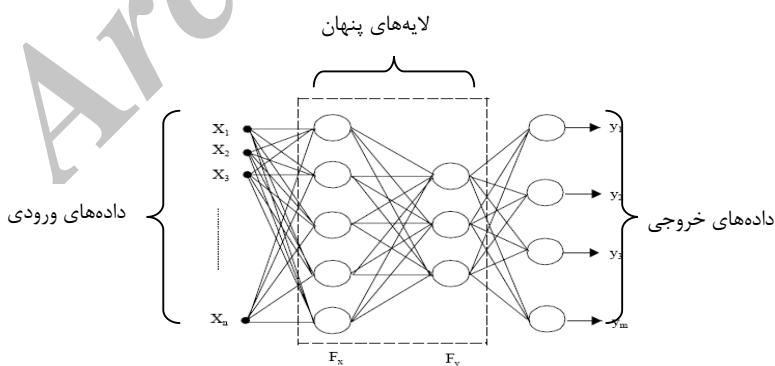
که در آن،  $W = [W_{1,1}, W_{1,2}, \dots, W_{1,R}]$  و  $\bar{P} = [P_1, P_2, \dots, P_R]^T$  و در نهایت، خروجی نرون به صورت رابطه (۳) خواهد بود:

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

عمولاییک نرون حتی با تعداد ورودی‌های زیاد نیز به تنها یک راه 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 پس انتشار و شبکه آبشاری پس انتشار است. به عنوان مثال، کبودان (۲۰۰۱) و همچنین یو و همکاران (۲۰۰۸) شبکه پیشخور پس انتشار را پیشنهاد نمودند. مالیک و ناصرالدین (۲۰۰۶) شبکه آبشاری پس انتشار را مناسب ارزیابی کردند. شبکه پیشخور پس انتشار 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 تعیین یافته و شبکه المان پس انتشار نیز که در برخی از مطالعات همانند اصفهانیان و امین ناصری (۱۳۸۷) مورد توجه قرار گرفته بود استفاده شد که در ادامه معرفی شده‌اند.

۱-۱. شبکه پیشخور پس انتشار<sup>۱</sup>  
در شکل (۳) یک نمونه از شبکه پیشخور پس انتشار 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 بودار داده‌های ورودی، Y بودار داده‌های خروجی و F تابع عملگر است که پردازش بر روی داده‌ها را انجام می‌دهد (ایلینا و همکاران، ۲۰۰۴).



شکل ۳. ساختار شبکه پیشخور پس انتشار با دو لایه پنهان

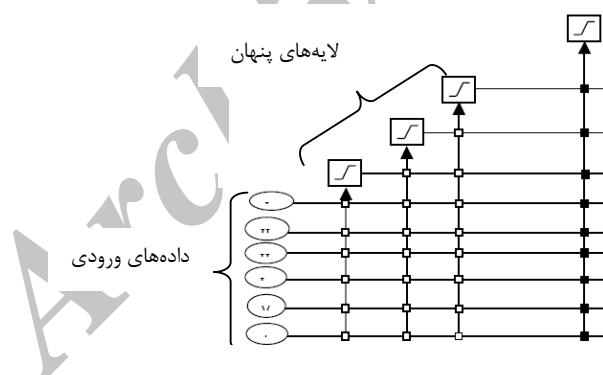
#### ۲-۱-۲. شبکه المان پس انتشار<sup>۱</sup>

شبکه المان نیز دارای ساختاری مشابه شبکه پیشخور پس انتشار است، اما از لحاظ نوع عملکرد با آن دارای تفاوت است. به این ترتیب که شبکه المان پس انتشار بر خلاف شبکه پیشخور پس انتشار 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 مجددًا 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 آبشاری پس انتشار<sup>۲</sup>

در شکل (۴) شبکه آبشاری پس انتشار 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 پایین تر 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).

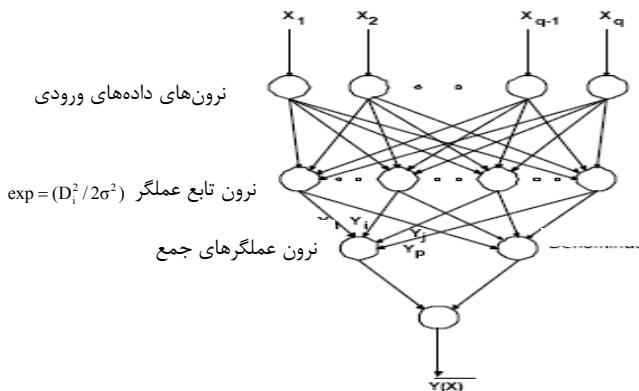
داده‌های خروجی



شکل ۴. ساختار شبکه آبشاری پس انتشار با سه لایه پنهان

۱-۴. شبکه رگرسیون تعمیم‌یافته<sup>۱</sup>

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



در شبکه رگرسیون تعمیم‌یافته 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  $\sigma$ : یک پارامتر است که مقادیر متفاوتی را اختیار می‌کند. در واقع، رابطه فوق رگرسیون کردن  $Y$  بر روی بردار  $X$  است. بر اساس این مطالعات استفاده از لایه پنهان فراتر از سه عدد می‌تواند 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 لونبرگ-مارکوآت و شبکه‌یوتی<sup>۲</sup> استفاده گردید.

## 1. Generalize Regression Network

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

## ۲-۲. الگوی خودرگرسیون میانگین متحرک<sup>۱</sup>

بطور کلی فرایندی را ARMA<sub>(p,q)</sub> 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 اختلال باشد. همچنین اگر یک سری زمانی پس از  $d$  مرتبه تفاضل گیری ساکن شود و سپس آنرا توسط فرایند ARMA<sub>(p,q)</sub> مدل‌سازی کنیم در این صورت سری زمانی اصلی، سری زمانی خود رگرسیونی میانگین متحرک اباسته ARIMA<sub>(p,d,q)</sub> می‌باشد (گجراتی، ۱۳۷۸). یک مدل عمومی ARMA<sub>(p,q)</sub> 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. مارسلینیو و همکاران (۲۰۰۶) به منظور انتخاب وقفه در پیش‌بینی سری‌های ماهانه متغیرهای کلان اقتصاد آمریکا با استفاده از الگوی اتورگرسیو<sup>۲</sup> از چهار معیار استفاده نمود که شامل انتخاب وقفه ثابت<sup>۴</sup>، انتخاب وقفه ثابت<sup>۱۲</sup>، معیار آکائیک و معیار شوارتز<sup>۳</sup> بود. پیندک 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<sup>۳</sup> وقفه را برای پیش‌ذیینی سالانه مناسب عنوان کردند. در مجموع می‌توان لگفت استفاده از پیش 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)<sup>۴</sup> و تابع خود همبستگی جزئی (PACF)<sup>۵</sup> است. این روش را در حالت کلی می‌توان به صورت زیر بیان نمود:

- در یک فرایند ARIMA<sub>(p,q)</sub> 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 (p,q) ARIMA تابع خود همبستگی جزئی پس از وقفه  $\vartheta$  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 اخلاق پس از برآورده فرایند موردنظر و نرمال بودن توزیع این جملات اخلاق 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 مورداستفاده در شبکه‌های عصبی بر اساس معیار آکائیک در مطالعه مالیک و ناصرالدین (۲۰۰۶) نیز مشاهده می‌شود.

### ۳-۲. انتخاب بهترین مدل پیش‌بینی

برای تمام روش‌های پیش‌بینی ابتدا می‌باشد داده‌های سری موردنظر را به دو قسمت تقسیم کرد. یک سری از آنها معمولاً برای آموزش یا بازش مدل مورداستفاده قرار می‌گیرند که آنها را اصطلاحاً داده‌های دستگرمی<sup>۱</sup> و سری دوم را که برای آزمون مدل بکار می‌روند را اصطلاحاً نمونه پیش‌بینی<sup>۲</sup> می‌نامند. در این مطالعه داده‌های مورداستفاده برای پیش‌بینی شامل سه گروه ۲۰، ۱۰ و ۳۰ درصد می‌باشد. در واقع، برای تمام مدل‌های پیش‌بینی محاسبات بر مبنای داده‌های دستگرمی انجام می‌شود و به کمک داده‌های دوره پیش‌بینی موردازمه قرار می‌گیرند. روش‌های مختلفی برای اندازه‌گیری دقیقت مدل‌های پیش‌بینی وجود دارد که رایج‌ترین آنها معیار ریشه میانگین مجذور خطاهای پیش‌بینی (RMSE)<sup>۳</sup> 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):

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

که در آن،  $\hat{y}$  و  $y$  به ترتیب مقادیر پیش‌بینی شده و واقعی سری مورداستگرمی هستند و  $h$  نیز تعداد مشاهدات مورداستگرمی باشد.  $T$  نیز داده‌های مورداستفاده 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 خطاهای (MAE)<sup>۱</sup> و معیار درصد میانگین خطاهای پیش‌بینی (MAPE)<sup>۲</sup>. 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 می‌نمایند. این شاخص‌ها به صورت زیر تعریف می‌شوند:

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

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

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

همچنین، به منظور مقایسه توان پیش‌بینی شبکه‌های یادشده از آماره دیبلد-ماریانو<sup>۳</sup> 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 مجدول 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 مجدد مقادیر خطای 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.

### ۳.۵۵۵۵۵۵۵

برای آموخت شبکه‌های عصبی علاوه بر وقتهای مختلف قیمت گازویل سنگاپور از قیمت نفت‌های وست تگراس ایترمیدیت 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 گازویل 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 تغیرات داده‌ها محاسبه و بر حسب تغیرات مثبت و منفی به دو گروه تفکیک شد و با استفاده از یک متغیر موهومی این الگوی تغیرات 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 منتظر با سری قیمت گازویل ایجاد و سپس بر اساس سری تصادفی اعداد مرتب گردید.<sup>۱</sup>

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 یادشده به ترتیب (۲۰-۸۰) و (۳۰-۷۰) 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 نرم افزار Matlab 7.1 استفاده شد. تخمین الگوی رگرسیونی خودرگرسیون میانگین متحرک نیز با استفاده از نرم افزار Eviews 5 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 ایستایی نمی‌باشند، اما پس از یکبار تفاضل‌گیری رفتاری ایستایی 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 (۱)-(۴) نیز خلاصه یافته‌های پیش‌بینی قیمت گازویل در بازار سنگابور 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 پسانشوار و شبکه آبشاری پسانشوار 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 نیوتونی موجب شده است تا شبکه نسبت به تعداد لایه پنهان هیچ حساسیتی نداشته باشد. اما با بکارگیری تابع آموزش لونبرگ- مارکوآت 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 پس انتشار به نظر می‌رسد استفاده از یک یا سه لایه پنهان موجب کاهش دقت پیش‌بینی می‌شود که با استفاده از تابع آموزش شبه‌نیوتونی با یک لایه پنهان خطای پیش‌بینی بطور نامطلوبی افزایش می‌یابد. البته استفاده از تابع آموزش شبه‌نیوتونی با یک لایه پنهان موجب بهبود پیش‌بینی‌های نسبت به شبکه‌های مبتنی بر تابع آموزش شبه‌نیوتونی شده است اما استفاده از سه لایه پنهان تحت تأثیر نوع تابع آموزش قرار نمی‌گیرد. شبکه رگرسیون تعییم یافته نیز تنها از الگوی رگرسیونی خودرگرسیون میانگین متحرک پیش‌بینی‌های بهتری دارد. برای پیش‌بینی ۱۰ درصد از داده‌ها می‌توان با استفاده از شبکه پیشخور پس انتشار با خطای کمتر از ۲ درصد پیش‌بینی ارائه نمود. این رقم برای شبکه آبشاری پس انتشار، شبکه المان پس انتشار و شبکه رگرسیون تعییم یافته ۲-۲/۵ 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 پس انتشار، آبشاری پس انتشار و المان پس انتشار استفاده از تابع آموزش شبه‌نیوتونی به معنای حذف نقش لایه‌های پنهان بوده است و همان طور که در جدول (۱) نیز مشخص شده است به دنبال استفاده از تابع آموزش شبه‌نیوتونی اثر تعداد لایه‌های پنهان بسیار نامحسوس ظاهر شده است. برخلاف آنچه در مورد اثر تعداد لایه پنهان بر دقت پیش‌بینی در شبکه‌های تحت آموزش شبه‌نیوتونی گفته شد در شبکه‌هایی که از تابع آموزش لونبرگ- مارکوآت 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 خط را موجب شده است. همانند شبکه‌های مورد استفاده پیش‌بینی‌های ارائه شده برای ۲۰ درصد از داده‌های قیمت گازویل توسط شبکه رگرسیون تعییم یافته 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 <sup>۳۰</sup> 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 آبشاری 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 تعییم‌یافته افزایش استفاده از سهم داده‌های پیش‌بینی موجب افزایش خطای پیش‌بینی شده است درحالی 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 تابع آموزش			لوبنیرگ- مارکوآت			شبینوتی		
نوع الگو			تعداد لایه‌های پنهان			درصد داده‌های پیش‌بینی		
۱	۲	۳	۱	۲	۳	۱	۲	۳
شبکه پیشخور			۱۰					
پس‌انتشار			۲۰					
شبکه آبشاری			۳۰					
پس‌انتشار			۱۰					
شبکه المان			۲۰					
پس‌انتشار			۳۰					
شبکه رگرسیون			۱۰					
تعییم‌یافته			۲۰					
الگوی خودرگرسیون			۳۰					
میانگین متحرک			۱۰					
میانگین متحرک			۲۰					
میانگین متحرک			۳۰					

مأخذ: نتایج تحقیق.

در جداول (۴) - (۲) نیز الگوهای دارای کمترین خطاب 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 موقوفیت کمترین خطاب پیش‌بینی را داشته‌اند (جدول ۲). البته تمایز میان تابع آموزش دشوار است زیرا شبکه دارای کمترین خطاب پیش‌بینی از تابع آموزش لونبرگ- مارکوآت استفاده کرده است شبکه دارای رتبه دوم از تابع آموزش شبه نیوتی و مجدداً در شبکه المان پس انتشار استفاده از تابع آموزش لونبرگ- مارکوآت کمترین خطاب 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 خطاب بالاتری دارند.

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

نوع الگو	شبکه پیشخور	شبکه آشنا	شبکه رگرسیون الگوی خودرگرسیون	ویژگی‌ها	
				پس انتشار	پس انتشار
نوع تابع آموزش	لونبرگ- مارکوآت	شبه نیوتی	لونبرگ- مارکوآت	تعیین یافته	میانگین متحرک
تعداد لایه‌های پنهان	-	-	۲	۱	۱
ریشه میانگین محدود	-	-	-	-	-
خطاهای پیش‌بینی	۱۱/۷۷	۴/۹۹	۳/۱۵	۲/۹۶	۲/۷۱
میانگین مطلق خطاهای	۸/۶۲	۲/۸۸	۲/۱۱	۱/۸۹	۱/۸۱
درصد میانگین	۳/۹۸	۲/۷۸	۲/۳۱	۲/۰۵	۱/۹۹
خطاهای پیش‌بینی	۲۲۳/۲	۹۴/۴۹	۹۴/۵۲	۹۴/۴۵	۹۴/۴۳
میانگین (۹۴/۷۰)	۵	۴	۳	۲	۱
رتبه					

مأخذ: نتایج تحقیق.

در جدول (۳) یافته‌های به دست آمده برای ۲۰ درصد از داده‌ها ارائه شده است. در این جدول کم‌خطاطرین 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 خطاب پیش‌بینی که به ترتیب شبکه المان پس انتشار و شبکه پیشخور پس انتشار هستند هر دو از تابع آموزش

لونبرگ - مارکوآت استفاده کرده‌اند و شبکه آبشاری پس‌انتشار که در رتبه سوم قرار دارد از تابع آموزش شبکه نیوتونی برای آموزش شبکه بهره گرفته است. بطور قطعی می‌توان گفت شبکه‌هایی که از تابع آموزش لونبرگ - مارکوآت استفاده می‌کنند از خطای پیش‌بینی کمتر از ۲ درصد برخوردار خواهند بود. در مورد شبکه آبشاری پس‌انتشار که از تابع آموزش شبکه نیوتونی استفاده می‌کند این رقم اندکی بالاتر از ۲ درصد است. این رقم در خصوص شبکه رگرسیونی تعیین‌یافته و الگوی رگرسیونی خود رگرسیون 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 - مارکوآت 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 آبشاری	شبکه المان	شبکه رگرسیون الگوی خود رگرسیون	ویژگی‌ها
						پس‌انتشار	پس‌انتشار	پس‌انتشار	تعیین‌یافته	میانگین متحرک	
		نوع تابع آموزش	لونبرگ - مارکوآت	شبکه نیوتونی	لونبرگ - مارکوآت	-	-	-	-	-	ریشه میانگین معجزه
		تعداد لایه‌های پنهان		۳	۱	۳					خطاهای پیش‌بینی
۹/۱۲	۴/۷۵			۲/۶۱	۲/۸۷	۲/۸۷					
۶/۴۰				۱/۷۶	۱/۹۳	۱/۷۷					میانگین مطلق خطاهای
۲/۱۳	۲/۶۷			۱/۹۲	۲/۰۸	۱/۸۷					درصد میانگین خطاهای پیش‌بینی
۲۰/۴۵	۹۸/۰۸			۹۷/۶۵	۹۷/۷۶	۹۷/۵۷					میانگین (۹۷/۷۲)
۵	۴			۱	۳	۲					رتبه
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 - مارکوآت استفاده نموده است و همچنین شبکه آبشاری پس‌انتشار تابع آموزش شبکه نیوتونی 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) بر حسب نوع تابع آموزش و همچنین تعداد لایه پنهان نمی‌توان میان شبکه‌ها تمايزی 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 تعیین یافته 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 گازویل بازار سنگاپور از طریق الگوهای مختلف  
با استفاده از ۳۰ درصد داده‌ها

نوع الگو ویژگی‌ها	شبکه پیشخور				
	شبکه آبشاری	شبکه المان	شبکه رگرسیون الگوی خودرگرسیون	تمیم یافته	پس انتشار
نوع تابع آموزش	لوبنرگ- مارکوآت	لوبنرگ- مارکوآت	-	-	-
تعداد لایه‌های پنهان	۱	۳	۱	۲	۲
ریشه میانگین مجدد	۲/۹۴	۲/۸۳	۲/۷۲	۴/۵۸	۷/۸۳
خطاهای پیش‌بینی	۱/۸۶	۱/۸۳	۱/۷۹	۲/۷۵	۵/۲۸
میانگین مطلق خطاهای	۲/۰۵	۲/۰۱	۲/۰۱	۲/۸۵	۲/۹۷
درصد میانگین	۱/۱۱	۹۴/۹۱	۹۴/۰۹	۹۴/۳۲	۱۷۲/۵
خطاهای پیش‌بینی	۳	۲	۱	۴	۵
میانگین (۹۴/۱۱)					
رتبه					

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 مجدد 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 عصی 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 لحظه 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 دبلد-ماریانو برای شبکه‌های بروسی شده

										درصد داده‌های پیش‌بینی	
۳۰		۲۰		۱۰							
شبکه رگرسیون تعمیم یافته		شبکه آماری پس انتشار		شبکه پیشخورد پس انتشار		شبکه رگرسیون تعمیم یافته		شبکه آماری پس انتشار		شبکه پیشخورد پس انتشار	(گلاسیون تعمیم یافته)
											آماری پس انتشار
											آشناز پس انتشار
-۰/۲۷	-۰/۱۱	-۰/۰۸	-	-۰/۲۷	-۰/۱۱	-۰/۰۸	-	-۰/۲۷	-۰/۱۱	-۰/۰۸	پیشخور پس انتشار
-۰/۲۴	-۰/۰۴	-۰/۰۸	-	-۰/۲۴	-۰/۱۱	-۰/۰۴	-	-۰/۲۴	-۰/۱۱	-۰/۰۴	آشماری پس انتشار
-۰/۲۹	-	-۰/۰۴	-۰/۱۱	-۰/۲۹	-	-۰/۰۴	-۰/۱۱	-۰/۲۹	-	-۰/۰۴	المان پس انتشار
-	-۰/۲۹	-۰/۰۴	-۰/۱۱	-	-۰/۲۹	-۰/۰۴	-۰/۱۱	-	-۰/۲۹	-۰/۰۴	رگرسیون تعمیم یافته
-۰/۲۳	۰/۰۶	۰/۰۰	-	-۰/۲۳	۰/۰۶	۰/۰۰	-	-۰/۲۳	۰/۰۶	۰/۰۰	پیشخور پس انتشار
-۰/۲۰	۰/۰۹	-	۰/۰۰	-۰/۲۰	۰/۰۹	-	۰/۰۰	-۰/۲۰	۰/۰۹	-	آشماری پس انتشار
-۰/۲۳	-	۰/۰۶	-	-۰/۲۳	-	۰/۰۶	-	-۰/۲۳	-	۰/۰۶	المان پس انتشار
-	-۰/۲۳	-۰/۰۰	-۰/۰۰	-	-۰/۲۳	-۰/۰۰	-۰/۰۰	-	-۰/۲۳	-۰/۰۰	رگرسیون تعمیم یافته
-۰/۱۷	۰/۰۶	۰/۰۴	-	-۰/۱۷	۰/۰۶	۰/۰۴	-	-۰/۱۷	۰/۰۶	۰/۰۴	پیشخور پس انتشار
-۰/۱۹	۰/۰۴	-	۰/۰۰	-۰/۱۹	۰/۰۴	-	۰/۰۰	-۰/۱۹	۰/۰۴	-	آشماری پس انتشار
-۰/۲۱	-	۰/۰۴	۰/۰۰	-۰/۲۱	-	۰/۰۴	۰/۰۰	-۰/۲۱	-	۰/۰۴	المان پس انتشار
-	-۰/۱۹	-۰/۰۰	-۰/۰۰	-	-۰/۱۹	-۰/۰۰	-۰/۰۰	-	-۰/۱۹	-۰/۰۰	رگرسیون تعمیم یافته

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 شبکه عصبی مصنوعی تمایل به پیش‌بینی روند آتی قیمت‌های این منابع بیشتر شده است. البته عمده‌تاً نفت خام مورد توجه بوده است، اما همان‌طور که در ابتدای مطالعه

نیز ذکر شد در مورد قیمت گازویل در بازار سنگاپور که به عنوان متغیر بیانگر قیمت گازویل 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 خطای  $3/48$  درصد به دست آمد. در حالی که در مطالعه حاضر برای پیش‌بینی هر سه گروه  $10$ ،  $20$  و  $30$  درصد این رقم تنها حدود  $2$  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 شریف‌النی (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 - مارکوآت استفاده می‌کند. علاوه بر این، مشخص شد در اغلب موارد استفاده از تابع آموزش شبه‌نیوتی منجر به عدم حساسیت شبکه نسبت به تعداد لایه‌های پنهان می‌شود، لذا بهتر است در مطالعات بر استفاده از تابع آموزش لونبرگ - مارکوآت تأکید بیشتری ورزیده شود.

در مورد تمام گروه از داده‌ها دو شبکه پیشخور پس انتشار و شبکه المان پس انتشار از تابع آموزش لونبرگ - مارکوآت و شبکه آبشاری پس انتشار از تابع آموزش شبه‌نیوتی استفاده می‌کند و این می‌تواند موجب صرفه‌جویی در دستیابی به نتایج مطلوب شود.

شبکه‌های دارای تابع آموزش شبه‌نیوتی تمايل 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 شبکه‌ایی که از تابع آموزش لونبرگ - مارکوآت استفاده می‌کند روند منظمی در تعداد لایه‌های پنهان دیده نمی‌شود.

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

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 به دنبال دارد لذا می‌توان ترکیب ۲۰-۸۰ درصد را به عنوان ترکیب مطلوب برای پیش‌بینی‌های قیمت گازویل پیشنهاد نمود.

#### منابع

- ابرشمی، 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 ۵۷-۵۸.
- ابرشمی، حمید، مهرآرا، محسن و یاسمهن 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.
- بهرادمهر، نفیسه (۱۳۸۷)، "پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و شبکه عصبی مصنوعی"، *فصلنامه مطالعات اقتصاد ایرانی*، سال ۵، شماره ۱۸، صص ۹۸-۸۱.
- شريف‌النبي، مصطفى (۱۳۷۸)، کاربرد شبکه‌های عصبی در پیش‌بینی: مطالعه موردی پیش‌بینی قیمت نفت، پایان‌نامه کارشناسی ارشد، گروه مدربت، دانشگاه شیراز.
- فرجامیا، ایمان، ناصری، محسن و سید‌محمد‌مهدی 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 اقتصاد سنجی*، ترجمه حمید ابراشمی، 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.
- Pindyich, 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.