

## ارائه یک مدل شبکه عصبی جهت پیش‌بینی کوتاه‌مدت قیمت نفت خام

مجید اصفهانیان و محمدرضا امین ناصری

**چکیده:** ایران یکی از پنج کشور بزرگ مالک ذخایر غنی نفتی در جهان است. علیرغم رشد صادرات محصولات غیرنفتی، هنوز هم بخش اعظم اقتصاد کلان کشور بر نفت متکی است و بیش از ۹۸٪ انرژی اولیه کشور از نفت تأمین می‌شود. بنابراین اهمیت تحقیق در زمینه مباحث مرتبط با اقتصاد نفت و بویژه مدلی که بتواند قیمت نفت را پیش‌بینی نماید، بر هیچکس پوشیده نیست. امروزه علاقه فراوانی به استفاده از سیستم‌های هوشمند در جهت بهبود کیفیت تصمیمات مالی بوجود آمده است. بویژه شبکه‌های عصبی که از طریق آموزش، توانایی یادگیری از تجارب گذشته و بهبود سطح کارایی خود را دارا هستند، در این رابطه جایگاه ویژه‌ای دارند. لذا در این تحقیق با استفاده از یادگیری «هدایت شده» یک مدل شبکه عصبی برای «پیش‌بینی ماهانه قیمت نفت خام»، توسعه داده شده است. در فرآیند توسعه این مدل، تأثیر انواع متغیرهای فنی و بنیادی، تعداد نرون‌های لایه ورودی، تعداد لایه‌ها و نرون‌های پنهان، توابع تبدیل لایه‌ها، پیش‌پردازش مناسب داده‌ها، تقسیمات مختلف داده‌ها برای انتخاب مجموعه‌های آموزش و آزمایش، انواع الگوریتم‌های یادگیری بهبودیافته و انواع شبکه با انجام آزمایش‌های فراوان بررسی شده است. در نهایت یک شبکه پیشخور سه‌لایه  $(N^{9-2-8-1})$  با میانگین خطای مطلق ۷۴ سنت در مجموعه آموزش و ۷۱ سنت در مجموعه آزمایش، بعنوان بهترین مدل انتخاب گردیده است.

**واژه‌های کلیدی:** قیمت نفت خام، شبکه عصبی، پیش‌بینی، مدل سازی غیرخطی، پیشگویی کوتاه‌مدت

### ۱. مقدمه

در دنیای صنعتی امروز با توجه به کاهش روزافزون منابع انرژی، ارزش این منابع روز به روز بیشتر میشود. بدیهی است، نفت بعنوان یکی از مهم‌ترین منابع مورد استفاده بشر، از اهمیت ویژه‌ای برخوردار است. از طرفی قیمت نفت، به خاطر اهمیت آن در بازارهای بین‌المللی، رابطه اساسی آن با اقتصاد کشورها و موقعیت استراتژیک آن در بین کالاهای اقتصادی، یکی از عوامل بسیار مؤثر در اقتصاد بین‌الملل بوده و نقش تعیین‌کننده‌ای در رکود و رونق اقتصاد بین‌الملل دارد.

در کشور ما، علیرغم رشد صادرات محصولات غیرنفتی در دهه گذشته، هنوز هم نفت عمده‌ترین منبع درآمد ارزی (حدود ۸۵

---

این مقاله در تاریخ ۸۳/۱/۱۵ دریافت و در تاریخ ۸۴/۴/۷ به تصویب نهایی رسیده است.


مجید اصفهانیان، کارشناس ارشد مدیریت سیستم و بهره‌وری، دانشگاه صنعت آب و برق، [esfahanian@pwut.ac.ir](mailto:esfahanian@pwut.ac.ir)

دکتر محمدرضا امین ناصری، دانشیار دانشگاه تربیت مدرس، [amin\\_naseri@modares.ac.ir](mailto:amin_naseri@modares.ac.ir)

درصد)، تأمین‌کننده بیش از ۹۸ درصد انرژی اولیه کشور و متوازن‌کننده بودجه عمومی بوده و بخش اعظم اقتصاد کلان کشور، مبتنی و متکی بر قیمت نفت است. همچنین قیمت نفت بر روی اجرای برنامه‌های پنج ساله تدوین شده، تأثیرات عمده‌ای می‌گذارد به نحوی که هر نوسان قیمت، اثرات تأیید کننده‌ای بر کل برنامه‌های اقتصادی دولت خواهد گذاشت.

بازار نفت، یکی از بازارهای پرتلاطم است که پیش‌بینی آینده آن می‌تواند در تصمیم‌گیری‌ها تأثیر مثبتی برجای بگذارد. هر چند وقوع بحران‌های نفتی که ناگهان در بازار نفت حادث میشود، درجه اطمینان بسیاری از این پیش‌بینی‌ها را با تردید مواجه می‌سازد. با آگاهی از قیمت نفت و پیش‌بینی صحیح آن می‌توان فرآیند تصمیم‌گیری خرید و فروش نفت در بازارهای جهانی را تسهیل و بهترین زمان انجام معاملات و سرمایه‌گذاری‌ها را تعیین نمود. واضح است که بدلیل رقابت و ناهماهنگی محسوسی که بین کشورهای عضو اوپک و اعضای غیر اوپک وجود دارد، منحنی عرضه و تقاضا در نفت به هم خورده و باعث بروز مشکلات عدیده‌ای برای کشورها

پیش‌بینی، عمل برون‌یابی را برای آینده انجام دهد. اغلب رویکردهای شبکه عصبی برای مسئله پیش‌بینی، یک شبکه چندلایه پیش‌خور را که با استفاده از الگوریتم پس‌انتشار خطا یا الگوریتم‌های بهبودیافته و اصلاح شده آن، آموزش داده شده است، بکار می‌برند [۸]. در پیش‌بینی سری‌های زمانی غیرخطی، بدون شک یکی از روش‌های کارآمد، روش پیش‌بینی با شبکه‌های عصبی است. برای سری‌های زمانی تک‌متغیره، ورودی‌های شبکه عصبی مقادیر مشاهدات گذشته داده‌ها و خروجی‌های شبکه عصبی مقادیر آینده آنهاست و هر یک از الگوهای ورودی/خروجی از پنجره‌ای به طول ثابت در طول سری تشکیل شده است. در این صورت مطابق شکل ۱، سری زمانی به وسیله ارائه پنجره متحرکی از یک یا چند ورودی و یک یا چند خروجی به شبکه عصبی، مدل می‌شود.



شکل ۱. استفاده از پنجره متحرک در طول سری زمانی، جهت مدل کردن سری زمانی

به عنوان مثال برای پیش‌بینی یک سری زمانی با استفاده از یک شبکه عصبی با  $i$  ورودی و یک خروجی می‌توان نوشت:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-i}) + \varepsilon_t \quad (1)$$

در این رابطه  $y_t$  مشاهده در لحظه  $t$  و  $\varepsilon_t$  مقدار خطا در لحظه  $t$  است. در این حالت اگر از یک شبکه عصبی به جای تابع  $f$  استفاده نماییم، یک مدل اتورگرسیو خواهیم داشت. حال فرض کنیم  $n$  مشاهده قبلی  $y_1$  و  $y_2$  و ... و  $y_n$  را به عنوان مجموعه‌ای برای آموزش شبکه عصبی در اختیار داریم و می‌خواهیم پیش‌بینی یک مرحله بعد را انجام دهیم. در این صورت یک شبکه عصبی با  $i$  ورودی و یک خروجی در نظر می‌گیریم و در نتیجه  $n-i$  الگوی آموزشی خواهیم داشت.

جدول ۱. الگوهای آموزشی

الگوی آموزشی	ورودی‌ها:	خروجی:
۱	$\{y_1, y_2, \dots, y_i\}$	$\{y_{i+1}\}$
۲	$\{y_2, y_3, \dots, y_{i+1}\}$	$\{y_{i+2}\}$
⋮	⋮	⋮
الگوی آموزشی $n-i$	$\{y_{n-i}, y_{n-i+1}, \dots, y_{n-1}\}$	$\{y_n\}$

می‌گردد. از جمله در کشوری نظیر ایران، که پیش‌بینی بودجه آن براساس قیمت نفت انجام می‌پذیرد، در صورت پیش‌بینی ناصحیح و دور از واقعیت قیمت نفت و تحقق نیافتن بودجه، دولت مجبور می‌شود برای جبران خطای پیش‌بینی از صندوق ذخیره ارزی برداشت کند و این مسئله به نفع اقتصاد کشور نخواهد بود. لذا این کالا همواره زمینه مناسبی برای انجام تحقیقات گسترده، در حوزه مسایل مالی و اقتصادی بوده است و اهمیت پیش‌بینی صحیح قیمت آن، بر هیچکس پوشیده نیست.

برای پیش‌بینی قیمت نفت خام روش‌های مختلفی توسط محققین بکار گرفته شده است. از جمله روش دلفی توسط کمیسیون انرژی کالیفرنیا مورد استفاده قرار گرفته است [۱]. لیائو و لین روش مدل‌های رگرسیونی را با استفاده از متغیرهای مستقل نظیر نسبت ذخایر نفت خاورمیانه، نرخ تغییرات تقاضای نفت جهان، نرخ تغییرات ذخایر جهانی گاز جهت پیش‌بینی قیمت نفت خام مورد استفاده قرار داده‌اند [۲].

از جمله پیش‌بینی‌کنندگان مرسوم قیمت نفت خام، «سازمان مدیریت اطلاعات انرژی آمریکا» است که با توسعه مدل‌های اقتصادسنجی به پیش‌بینی قیمت نفت می‌پردازد. میانگین خطای مطلق پیش‌بینی‌های کوتاه‌مدت این سازمان در حدود ۷۰ سنت است [۳]. آبرامسون با استفاده از شبکه‌های احتمالی به پیش‌بینی قیمت‌های متوسط سالانه نفت خام WTI برای سال‌های ۱۹۹۳ تا ۱۹۹۵ پرداخته است و با بررسی تأثیر ۵۴۰۰۰ سناریوی مختلف به مدلی با  $R^2 \sim 0.76$  دست یافته است [۴]. کابودان در سال ۲۰۰۱ با استفاده از قیمت‌های نفت خام از سال ۱۹۹۲ تا ۱۹۹۸ و به کمک شبکه‌های تک‌لایه عصبی آموزش دیده با الگوریتم پس‌انتشار خطای استاتیک به پیش‌بینی قیمت نفت خام پرداخته است. ملاک مقایسه مدل‌ها، تنها MSE در نظر گرفته شده است. در نهایت این محقق مدل «قدم زدن تصادفی» را مناسبتر از شبکه‌های عصبی معرفی نموده است [۵].

## ۲. شبکه‌های عصبی در حوزه پیش‌بینی سری‌های زمانی

پیش‌بینی رفتار سیستم‌های پیچیده، یکی از کاربردهای گسترده شبکه‌های عصبی است. بویژه کاربردهایی نظیر پیش‌بینی وضع هوا، پیش‌بینی ورشکستگی شرکت‌های تجاری، پیش‌بینی دبی رودخانه، پیش‌بینی نرخ ارز، پیش‌بینی قیمت سهام، پیش‌بینی تولید ناخالص داخلی و دیگر پیش‌بینی‌های اقتصادی، بصورت گسترده مورد مطالعه قرار گرفته است [۶، ۷، ۸، ۹، ۱۰]. در فرآیند پیش‌بینی توسط شبکه‌های عصبی که با استفاده از یک سری زمانی انجام می‌شود، معمولاً مجموعه‌ای از داده‌ها به عنوان ورودی در اختیار شبکه عصبی قرار می‌گیرد تا شبکه با تخمین رفتار سیستم مورد

<sup>1</sup> Energy Information Administration

<sup>2</sup> Random Walk Model

«تغییرات مثبت» و «تغییرات منفی» که افزایش و کاهش قیمت نفت را با استفاده از رابطه (۳) از هم جدا می‌کند.

$$\Delta Y_t = \Delta Y_{Pt} + \Delta Y_{Nt} \quad (3)$$

در این رابطه  $\Delta Y_{Pt}$  تغییرات مثبت و  $\Delta Y_{Nt}$  تغییرات منفی است. اگر  $\Delta Y > 0$  باشد  $\Delta Y_p = \Delta Y$  و  $\Delta Y_n = 0$  خواهد بود و اگر  $\Delta Y < 0$  باشد،  $\Delta Y_p = 0$  و  $\Delta Y_n = \Delta Y$  خواهد بود. روش دوم، روش تفکیک قیمت به «حداکثر قیمت»، «کاهش تراکمی» و «افزایش تراکمی» است که توسط دارگی و گیتلی برای تفکیک تغییرات قیمت پیشنهاد شده است و با روابط (۴) تا (۷) محاسبه می‌شود [۱۴].

$$\Delta Y_t = Y_{Maxt} + Y_{ct} + Y_{Rt} \quad (4)$$

$$Y_{Maxt} = \max(Y_0, Y_1, Y_2, \dots, Y_t) \quad (5)$$

$$Y_{ct} = \sum_{i=0}^t \min\{0, [(Y_{Max_{i-1}} - Y_{i-1}) - (Y_{Max_i} - Y_i)]\} \quad (6)$$

$$Y_{Rt} = \sum_{i=0}^t \max\{0, [(Y_{Max_{i-1}} - Y_{i-1}) - (Y_{Max_i} - Y_i)]\} \quad (7)$$

در این رابطه‌ها  $Y_{Maxt}$  حداکثر قیمت،  $Y_{ct}$  کاهش تراکمی و  $Y_{Rt}$  افزایش تراکمی است.

روش سوم، روش تفکیک قیمت به «تغییرات قیمت از قیمت حداکثر  $\Delta Y_t$ »، «تغییرات کمتر از قیمت حداکثر و بیشتر از قیمت قبلی  $\Delta Y_2$ » و «تغییرات کاهش قیمت  $\Delta Y_3$ » است که با استفاده از روابط (۸) تا (۱۱) محاسبه می‌گردد.

$$\Delta Y_t = \Delta Y1_t + \Delta Y2_t + \Delta Y3_t \quad (8)$$

$$\Delta Y1_t = \begin{cases} Y_t - Y_{t-1} & , Y_t = Y_{Max_t} \\ 0 & , \text{Otherwise} \end{cases} \quad (9)$$

$$\Delta Y2_t = \begin{cases} Y_t - Y_{t-1} & , Y_{t-1} \leq Y_t < Y_{Max_t} \\ 0 & , \text{Otherwise} \end{cases} \quad (10)$$

$$\Delta Y3_t = \begin{cases} Y_t - Y_{t-1} & , Y_t < Y_{t-1} \\ 0 & , \text{Otherwise} \end{cases} \quad (11)$$

#### ۴. معیارهای عملکرد<sup>۶</sup>

در این تحقیق، عملکرد پیش‌بینی مدل توسط معیارهای عملکرد مختلفی سنجیده شده است زیرا هیچ گونه اجماع کلی بر روی بهترین معیار عملکرد، جهت ارزیابی مدل پیش‌بینی وجود ندارد [۹]. معمولاً محققین مختلف از سه یا چهار معیار عملکرد در کنار یکدیگر استفاده می‌نمایند [۸، ۹، ۱۲، ۱۶، ۲۳]. در این تحقیق از معیارهای

در صورتی که یک الگوی آموزشی ورودی به شبکه ارائه شود و شبکه به جای  $Y$  مقدار  $\hat{Y}$  را پاسخ دهد، هدف از آموزش شبکه پیدا کردن وزن‌های شبکه در جهت کمینه کردن خطای کلی پیش‌بینی است. بطور مثال با در نظر گرفتن مجموع مربعات خطا<sup>۳</sup> بعنوان خطای کلی پیش‌بینی، هدف آموزش کمینه کردن رابطه (۲) است.

$$SSE = \sum_{j=1}^{n-i} (y_j - \hat{y}_j)^2 \quad (2)$$

بعد از آموزش شبکه یا پیدا کردن وزن‌های متناظر با حداقل خطای کلی پیش‌بینی، سری زمانی توسط شبکه عصبی مدل شده و می‌توان با ارائه یک الگوی آموزشی دلخواه به طول  $i$  نظیر  $(Y_{n-i+1}, Y_{n-i+2}, \dots, Y_n)$  به شبکه، مقدار  $Y_{n+1}$  را توسط شبکه پیش‌بینی نمود.

#### ۳. داده‌ها

داده‌های مورد استفاده در این تحقیق، شامل دو بخش فنی و بنیادی است. داده‌های فنی، همان قیمت‌های نفت خام، وقفه‌های<sup>۴</sup> آن و مشتقات قیمت است. درحالی که داده‌های بنیادی، داده‌هایی از بازارهای دیگر است که ممکن است بر روی مسئله موردنظر تأثیر داشته باشد. داده‌های فنی، بویژه قیمت‌های نفت خام و برخی از داده‌های بنیادی نظیر تولید نفت خام اوپک و جهان، از «سازمان مدیریت اطلاعات انرژی آمریکا» و دیگر داده‌های بنیادی نظیر نرخ رشد اقتصادی و جمعیت جهان از «بانک جهانی» دریافت گردیده است.

سری زمانی قیمت‌های نفت خام شامل ۳۲۴ قیمت ماهانه مربوط به «هزینه دستیابی پالایشگر برای نفت خام وارد شده<sup>۵</sup>»، برای سال‌های ۱۹۷۴ تا ۲۰۰۱ می‌باشد. قیمت‌های ذکرشده از تقسیم مجموع کل هزینه‌های خرید پالایشگران آمریکا بر حجم کل خریدهای پالایشگران بدست می‌آید و اصطلاحاً RAC نامیده می‌شود. این قیمت‌ها برحسب دلار اسمی برای هر بشکه است. دلیل استفاده از این داده‌ها به جای استفاده از یکی از نفت خام‌های شاخص نظیر برنت یا وست تگزاس اینترمدیت، امکان دستیابی به این داده‌ها برای یک بازه حدوداً ۳۰ ساله است که جهت کار با شبکه‌های عصبی مناسب می‌باشد.

جهت تهیه داده‌های برنت و وست تگزاس اینترمدیت تلاش شد از سازمان مدیریت اطلاعات انرژی آمریکا کمک گرفته شود. ولی متأسفانه داده‌های این سازمان به بعد از سال ۱۹۸۶ محدود می‌گردید. علاوه بر داده‌های قیمت نفت خام، داده‌های تغییرات قیمت نفت خام نیز با استفاده از سری زمانی قیمت و با توجه به روش‌های موجود تولید شده است [۱۳].

روش اول از روش‌های مذکور عبارت است از تفکیک قیمت به

<sup>3</sup> Sum of Squared Errors (SSE)

<sup>4</sup> Lags

<sup>5</sup> Refiner Acquisition Cost of Crude Oil

<sup>6</sup> Performance Criteria

حد» وجود دارد و در صورت کوچک در نظر گرفتن آن، شبکه نخواهد توانست به اندازه کافی به داده‌های آموزش منطبق شود و «انطباق کمتر از حد» رخ خواهد داد.

$$MSEReg = \gamma.MSE + (1 - \gamma)MSW \quad (12)$$

$$MSW = \frac{1}{n} \sum_{i=1}^n W_i^2 \quad (13)$$

نتایج آزمایش‌ها نشان داد که بهترین نتایج در حالت استفاده از تابع عملکرد MAE بدست می‌آید.

## ۲-۵. آزمون انواع داده‌های فنی و بنیادی

داده‌های تولید شده توسط سه روش ذکر شده در بخش ۳، بعنوان ورودی مدل مورد استفاده و آزمایش قرار گرفته است. علاوه بر این وقفه‌های اول تا دوازدهم قیمت نفت خام، درصد تغییر قیمت نسبت به یک تا ۱۲ ماه گذشته و میانگین قیمت دو تا ۱۲ ماه گذشته، بعنوان داده‌های فنی و تولید نفت خام جهان و اوپک، جمعیت جهان، رشد اقتصادی جهان و رشد اقتصادی کشورهای توسعه‌یافته، ماه و فصل مرتبط با یک قیمت، بعنوان داده‌های بنیادی به مدل وارد گردیده است. نتایج حاصل نشان می‌دهد که به جز وقفه‌های اول تا نهم قیمت، هیچ یک از ورودی‌های دیگر نمی‌تواند عملکرد مدل را بهبود بخشد. نتیجه بدست آمده توسط کابودان در مدل‌های الگوریتم ژنتیک و شبکه عصبی پیش‌بینی قیمت نفت، مؤید صحت این موضوع است [۵].

## ۳-۵. پیش‌پردازش داده‌ها

نظر به این که در برخی از مواقع، در صورت انجام پیش‌پردازش مناسب بر روی داده‌ها، شبکه عملکرد بهتری را از خود نشان می‌دهد [۱۷، ۱۶، ۱۵، ۹، ۸، ۷، ۶، ۱۱، ۱۰]. پردازش‌های مختلفی از جمله نرمال‌سازی خطی در فاصله [۱-]، نرمال‌سازی استاندارد (میانگین صفر و انحراف معیار یک) و پردازش لگاریتمی بر روی داده‌ها انجام شده است. در نهایت با انجام ۱۶۸۰ آزمایش مختلف، شبکه در قبال پردازش لگاریتمی داده‌ها، عملکرد بهتری را از خود نشان داده است.

## ۴-۵. نسبت داده‌های آموزش و آزمایش

بطور معمول داده‌های سری زمانی به دو بخش داده‌های «آموزش» و «آزمایش» تقسیم می‌شود. مجموعه آموزش که از زوج الگوهای «ورودی/خروجی هدف» تشکیل شده، برای آموزش یک کار خاص به شبکه استفاده می‌شود. بعد از توقف آموزش، از مجموعه داده‌های آزمایش، برای بررسی کارایی شبکه و اینکه چقدر این کار خاص را فرا گرفته است، استفاده می‌شود و پاسخ مدل در قبال داده‌های آزمایش با مقادیر واقعی مقایسه می‌شود. غالباً اختصاص داده‌ها به این دو مجموعه، به یکی از نسبت‌های ۱۰٪-۹۰٪، ۲۰٪-۸۰٪ و یا

عملکرد R2، MSE، MAE، SSE، MAPE، MdAPE، Variance، CUT و CDT بر روی مجموعه آزمایش و معیار اطلاعات آکائیک علاوه بر معیارهای ذکر شده بر روی مجموعه آموزش، استفاده شده است. افزایش معیارهای R2، DS، CUT، CDT و کاهش بقیه معیارها بهبود عملکرد شبکه را نشان می‌دهد. Variance نشان‌دهنده واریانس مانده‌هاست ( $\hat{\sigma}^2$ ) و کاهش آن معادل با افزایش ضریب تعیین اصلاح‌شده<sup>۷</sup> است [۲۰]. DS نیز نشان‌دهنده میزان تشخیص صحیح روند است و اجزای آن یعنی CUT و CDT تشخیص روند صحیح رو به بالا و رو به پایین را نشان می‌دهد.

## ۵. طراحی مدل شبکه عصبی پیش‌بینی قیمت

برآورد پارامترها در یک مدل شبکه عصبی، یک فرآیند سیستماتیک نیست [۲۰]. بلکه با استفاده از روش سعی و خطا و تکرار آزمایش‌ها امکان‌پذیر است [۱۷]. در این تحقیق، جهت تحلیل داده‌ها و برآورد پارامترهای مدل از نرم‌افزار MATLAB استفاده شده است. هر آزمایش ۱۰ بار تکرار گردیده و میانگین معیارهای عملکرد، بعنوان نتیجه نهایی یک بار آزمایش در نظر گرفته شده است [۲۲]. ادبیات موضوع نشان می‌دهد که اکثر محققین بر این نکته توافق نظر دارند که شبکه‌های عصبی پیش‌خور، به عنوان تقریب زنده جهانی مطرح هستند و کاربرد فراوانی در تخمین و تقریب‌زنی توابع دارند [۹، ۱۲، ۱۷]. ولی در این تحقیق علاوه بر شبکه‌های پیش‌خور (Feed Forward)، شبکه‌های آبخاری (Cascade Forward)، المان (Elman) و رگرسیون تعمیم‌یافته (GRNN) نیز مورد آزمایش قرار گرفته است.

## ۱-۵. انتخاب بهترین تابع عملکرد شبکه

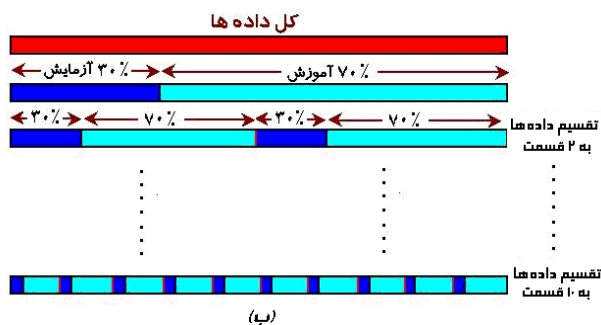
در فرآیند یادگیری شبکه، بطور معمول MSE بعنوان تابع عملکرد شبکه در نظر گرفته شده و تلاش می‌شود مجموع مربعات خطا بر روی داده‌های آموزش حداقل گردد [۶، ۷، ۸، ۹، ۱۱، ۱۰]. ولی در این تحقیق ۱۶۸۰ آزمایش مختلف جهت بررسی تأثیر توابع عملکرد MAE، SSE، MSEReg و علاوه بر MSE انجام شده است. در تابع MSEReg، تابع عملکرد معمول شبکه یعنی MSE به گونه‌ای اصلاح می‌شود که خاصیت تعمیم شبکه بهبود یابد. این کار با افزودن یک عبارت به MSE مطابق رابطه (۱۲) که وظیفه کمینه‌کردن مجموع مربعات وزن‌ها و بایاس‌های شبکه را بعهدہ دارد، انجام می‌شود [۱۵]. در رابطه (۱۲)  $\gamma$  نسبت عملکرد نامیده می‌شود و زمانی که مقدار ۰/۵ به آن تخصیص داده شود به این مفهوم است که به MSE و MSW وزن برابر داده شده است و حداقل نمودن هر دو تابع دارای اهمیت برابر است. در آزمایش‌های انجام شده  $\gamma$  برابر ۰/۵ در نظر گرفته شده است زیرا تعیین  $\gamma$  بهینه، کار ساده‌ای نیست و اگر بزرگ در نظر گرفته شود، احتمال بروز مشکل «انطباق بیش از

<sup>۷</sup>  $R^2_{adjust}$


در نهایت بهترین عملکرد مدل مطابق شکل ۲ (ب) با تقسیم داده‌ها به ۶ قسمت و برداشت ۷۰٪ داده جهت مجموعه آموزش و ۳۰٪ داده جهت مجموعه آزمایش حاصل گردیده است.

#### ۵-۵. انتخاب ساختار یا معماری شبکه

آزمایش‌های فراوانی جهت تعیین «ساختار» یا «معماری» شبکه انجام گردیده است. از جمله تأثیر توابع تبدیل مختلف برای لایه ورودی و لایه‌های پنهان شبکه بررسی شده است. لایه خروجی شبکه با توجه به ماهیت مسئله، یعنی پیش‌بینی قیمت ماه آینده، دارای یک نرون خروجی و تابع تبدیل خطی می‌باشد.



۳۰٪-۷۰٪ انجام می‌شود [۱۹]. برخی از محققین در صورت وجود داده‌ها به اندازه کافی، داده‌ها را به جای دو گروه به سه گروه تقسیم می‌کنند و علاوه بر دو مجموعه ذکر شده، یک مجموعه «اعتبار» هم در نظر می‌گیرند [۲۰ و ۲۱]. در این تحقیق با انجام ۶۳۰۰ آزمایش مختلف، در ابتدا برای تعیین اندازه مناسب داده‌ها، نسبت‌های ۷۰، ۷۵، ۸۰، ۸۵ و ۹۰ درصد برای مجموعه آموزش و باقیمانده داده‌ها برای مجموعه آزمایش در نظر گرفته شده که بهترین عملکرد مدل مطابق شکل ۲ (الف) در قبال تقسیم داده‌ها به نسبت ۳۰٪-۷۰٪ بدست آمده است. پس از آن داده‌ها به یک تا ۱۰ قسمت تقسیم و از هر قسمت به نسبت‌های ۳۰٪-۷۰٪ داده برداشت شده و به مجموعه‌های آموزش و آزمایش اختصاص داده شده است.



شکل ۲. نحوه تخصیص داده‌ها به مجموعه‌های آموزش و آزمایش

الگوریتم شبه نیوتنی BFGS، الگوریتم شبه نیوتنی OSS، الگوریتم لونیبرگ-مارکوآت و الگوریتم پس‌انتشار خطا با تنظیم بیزی، با انجام ۳۷۸۰ آزمایش بررسی گردیده است. در بین این الگوریتم‌ها، الگوریتم «لونیبرگ-مارکوآت» بهترین عملکرد را برای شبکه حاصل نموده است.

#### ۷-۵. تعداد ورودی‌های شبکه

انتخاب تعداد مقادیر تأخیریافته (وقفه‌ها) جهت وارد نمودن به شبکه، بحرانی‌ترین متغیر تصمیم در مسئله پیش‌بینی سری‌های زمانی است. زیرا این بردار حاوی اطلاعات مهمی در مورد ساختار پیچیده داده‌هاست. به طور کلی هیچ روش سیستماتیک پذیرفته شده‌ای برای تعداد ورودی بهینه وجود ندارد [۱۶، ۱۷ و ۱۹]. برخی از محققین معتقدند در پیش‌بینی ماهانه، مقادیر تأخیریافته تا دو سال قبل باید در نظر گرفته شود [۲۳]. در این تحقیق بعد از انجام ۱۵۶۰ آزمایش مختلف و با در نظر گرفتن معیار اطلاعات آکائیک برای مجموعه آموزش جهت رعایت «اصل صرفه‌جویی»<sup>۸</sup>، علاوه بر معیارهای معمول عملکرد شبکه، تعداد ۹ گره ورودی برای شبکه مناسب تشخیص داده شد. لذا قیمت‌های یک تا ۹ ماه گذشته باید بعنوان ورودی به مدل وارد گردد.

در مورد لایه ورودی و لایه‌های پنهان، با انجام ۵۰۴۰ آزمایش مختلف، تأثیر توابع تبدیل خطی، لجستیک و تانژانت هیپربولیک برای این لایه‌ها بررسی گردید. این آزمایش‌ها در دو حالت مختلف پیش‌پردازش لگاریتمی و بدون پیش‌پردازش و همچنین با تأثیر دادن متغیرهای بنیادی تولید نفت خام و بدون تأثیر دادن این متغیرها، تکرار گردیده و در کلیه حالات مشاهده گردید که شبکه در شرایط استفاده از تابع تبدیل خطی برای همه لایه‌ها، عملکرد بهتری را از خود نشان می‌دهد. دلیل این مسئله در ماهیت و طبیعت داده‌ها نهفته است و شبکه بدون فشردن مقادیر ورودی در فاصله‌ای خاص، توانسته است عملکرد خوبی را از خود نشان دهد.

#### ۶-۵. الگوریتم آموزش شبکه

قاعده یادگیری در شبکه عصبی، جهت یاد دادن کاری خاص به شبکه، استفاده می‌شود. برای این کار از رویه‌ای که وزن‌ها و بایاس‌های شبکه را اصلاح می‌نماید استفاده می‌شود که «الگوریتم آموزش» نامیده می‌شود [۱۵]. استفاده از الگوریتم‌هایی نظیر لونیبرگ-مارکوآت و یا الگوریتم شبه نیوتنی BFGS توسط محققین توصیه شده است [۲۳]. در این تحقیق جهت آموزش مدل پیش‌بینی قیمت، تأثیر الگوریتم‌های پس‌انتشار ارتجاعی، گرادیان همجوار با اصلاح فلچر-ریوز، گرادیان همجوار با اصلاح پولاک-ریبر، گرادیان همجوار با اصلاح پاول-بیل، گرادیان همجوار مقیاس‌بندی شده،

<sup>8</sup> Parsimony

## ۸-۵. تعداد لایه‌ها و نرون‌های شبکه

در شبکه با دو لایه پنهان، بهترین نتایج در حالتی بدست آمده است که در لایه پنهان اول، ۲ نرون و در لایه پنهان دوم، ۸ نرون وجود داشته است.

همچنین در شبکه با سه لایه پنهان، بهترین نتایج در حالات مختلفی به شرح جدول ۲ بدست آمده که شبکه با مجموع ۱۰ نرون ( $N^{9-2-1-7-1}$ ) جهت رعایت اصل صرفه‌جویی، به عنوان نماینده این گروه در نظر گرفته شده است.

## جدول ۲. نتایج آزمایش‌های انجام شده برای تعیین

بهترین شبکه «سه لایه»

تعداد نرون‌ها در لایه اول	۱	۱	۲	۳	۵	۸	۹	۹	۱۰
تعداد نرون‌ها در لایه دوم	۵	۱۰	۱	۵	۱	۵	۲	۵	۲
تعداد نرون‌ها در لایه سوم	۵	۷	۷	۷	۵	۱	۵	۱	۴

با مقایسه نتایج بدست آمده از شبکه‌های یک، دو و سه لایه مطابق جدول ۳ و با در نظر گرفتن اصل صرفه‌جویی در تعداد لایه‌ها و گره‌های پنهان، در نهایت شبکه با دو لایه پنهان و به ترتیب ۲ و ۸ نرون در لایه‌های پنهان اول و دوم ( $N^{9-2-8-1}$ )، که دارای بیشترین تعداد معیار بهینه است به عنوان شبکه نهایی حاصل از انجام آزمایش‌های این بخش، انتخاب شده است.

بعد از تعداد ورودی شبکه، تعداد لایه‌های پنهان شبکه، از دیگر متغیرهای بحرانی است. ادبیات موضوع نشان می‌دهد که به ندرت شبکه‌ای با بیش از سه لایه پنهان در مسایل پیش‌بینی، بهبود نشان داده است [۱۷]. ضمناً در صورت افزایش تعداد لایه‌ها، ممکن است شبکه دچار مشکل «انطباق بیش از حد»<sup>۹</sup> شود. در این تحقیق در شبکه‌های دارای یک و دو لایه پنهان، تعداد نرون‌های لایه پنهان از یک تا دو برابر تعداد گره‌های ورودی (۲×۹) آزمایش شده است. زیرا به صورت تئوری، محدودیتی در تعداد نرون‌های درون لایه پنهان وجود ندارد ولی در ادبیات موضوع به ندرت دیده شده که این تعداد از دو برابر تعداد گره‌های ورودی، تجاوز نماید [۹ و ۱۹]. در شبکه سه لایه برخلاف اغلب محققین که کار را با تعداد نرون بهینه بدست آمده برای لایه اول و لایه دوم ادامه می‌دهند، کلیه حالات مختلف آزمایش شده است. در اینجا با تغییر نرون‌های هر یک از سه لایه از یک تا ۱۰ نرون، ۱۰۰۰ شبکه مختلف سه‌لایه، مورد آزمایش قرار گرفته است. با احتساب ۱۰ بار تکرار هر آزمایش، تعداد ۱۳۴۲۰ آزمایش مختلف در این بخش برای تعیین تعداد لایه‌ها و گره‌های پنهان انجام شده است. بهترین نتایج مربوط به شبکه یک لایه بدون توجه به معیار اطلاعات آکائیک با ۲ و ۱۴ نرون در لایه پنهان بدست آمده که بر طبق اصل صرفه‌جویی و با در نظر گرفتن این معیار بر روی مجموعه آموزش، شبکه با ۲ نرون ارجحیت دارد.

## جدول ۳. مقایسه معیارهای عملکرد، برای شبکه‌هایی با یک، دو و سه لایه پنهان

تعداد لایه‌ها	آزمایش											آموزش
	۱ لایه	۲ لایه	۳ لایه	R2	MAPE	MdAPE	MSE	SSE	MAE	DS	Variance	
۱	۲	-	-	۰.۹۷	۳.۵۴	۲.۶۰	۰.۹۹	۹۷.۹۷	۰.۷۳	۶۸.۶۹	۰.۹۸	۰.۲۱
۲	۲	۸	-	۰.۹۷	۳.۴۸	۲.۶۵	۰.۹۶	۹۵.۱۳	۰.۷۱	۶۵.۶۶	۰.۹۵	۰.۲۹
۳	۲	۱	۷	۰.۹۷	۳.۵۱	۲.۷۱	۰.۹۵	۹۳.۷۴	۰.۷۱	۶۵.۶۶	۰.۹۴	۰.۳۲

## ۹-۵. نوع شبکه

مطابق نتایج ارائه شده در جدول ۴ بیشترین تعداد معیار عملکرد برای شبکه عصبی پیشخور به دست آمده است.

شبکه در این بخش آزمایش‌های مختلفی جهت تعیین نوع شبکه عصبی مناسب برای پیش‌بینی انجام شده است. آزمایش‌ها برای شبکه‌های عصبی پیشخور، آبخاری، المان و رگرسیون تعمیم یافته انجام شده است.

## جدول ۴. مقایسه معیارهای عملکرد برای انواع مختلف شبکه عصبی


Net Type	R2	MAPE	MdAPE	SSE	MSE	AE	MAE	DS	CUT	CDT	Variance
پیشخور	۰.۹۷	۳.۴۸	۲.۶۵	۹۵.۱	۰.۹۶۱	۷۰.۳۵	۰.۷۱	۶۵.۷	۳۴.۳	۳۱.۳	۰.۹۵
المان	۰.۹۷	۳.۵۴	۲.۷۳	۹۸.۷	۰.۹۹۷	۷۱.۷۷	۰.۷۲	۶۷.۷	۳۶.۴	۳۱.۳	۱
آبخاری	۰.۹۷	۳.۵۴	۲.۶۹	۹۸.۶	۰.۹۹۶	۷۱.۹۱	۰.۷۳	۶۸.۷	۳۶.۴	۳۲.۳	۱
رگرسیون تعمیم یافته	۰.۹۷	۳.۵۴	۲.۶۹	۹۸.۶	۰.۹۹۶	۷۱.۹۱	۰.۷۳	۶۸.۷	۳۶.۴	۳۲.۳	۱

<sup>۹</sup> Over Fitting

جدول ۵ ارائه گردیده است. جدول ۶ معیارهای عملکرد شبکه نهایی پیش‌بینی قیمت را برای مجموعه‌های آموزش و آزمایش نشان می‌دهد.

۱۰-۵. شبکه نهایی پیش‌بینی قیمت

مطابق شکل ۳ شبکه نهایی پیش‌بینی قیمت، یک شبکه پیشخور با ساختار  $N^{9-2-8-1}$  است. وزن‌ها ( $W$ ) و مقادیر اربیب ( $b$ ) این شبکه، در




شکل ۳. شبکه نهایی پیش‌بینی قیمت ماهانه نفت خام

جدول ۵. وزن‌ها و مقادیر اربیب شبکه نهایی پیش‌بینی قیمت

Input Weights		Layer Weights			Biases		
$W_{ij}^1$		$W_{jk}^2$		$W_{kl}^3$	$b_j^1$	$b_k^2$	$b_l^3$
۰.۹۷	-۰.۷۲	۰.۰۳	۰.۴۴	۰.۴۴	-۰.۷۰	۰.۴۸	۰.۱۰
-۰.۸۰	-۰.۶۳	۰.۳۱	۰.۷۷	۰.۷۷	-۰.۱۰	۰.۳۲	
-۰.۴۲	-۰.۹۸	۰.۸۸	۰.۹۶	۰.۹۶		۰.۰۳	
۰.۱۴	۰.۲۷	-۰.۹۰	-۰.۱۷	-۰.۱۷		-۰.۶۰	
-۰.۶۳	-۱.۰۵	۰.۸۵	۰.۰۶	۰.۰۶		-۰.۷۷	
۰.۰۶	-۰.۰۳	-۰.۱۵	۰.۴۰	۰.۴۰		۰.۲۳	
۰.۴۹	۰.۹۵	۰.۷۸	-۰.۱۵	-۰.۱۵		-۰.۲۸	
۰.۳۳	۰.۴۲	۰.۶۷	-۰.۰۴	-۰.۰۴		-۰.۳۶	
۰.۳۴	۰.۹۴						

جدول ۶. معیارهای عملکرد شبکه نهایی پیش‌بینی قیمت

مجموعه داده‌ها	R2	MAPE	MdAPE	SSE	MSE	AE	MAE	DS	CUT	CDT	Variance
آموزش	۰.۹۸	۳.۹۳	۲.۴۸	۲۸۵.۹	۱.۲۵۴	۱۶۸.۱۴	۰.۷۴	۶۱.۸	۳۴.۶	۲۷.۲	۱.۳
آزمایش	۰.۹۷	۳.۴۸	۲.۶۵	۹۵.۱	۰.۹۶۱	۷۰.۳۵	۰.۷۱	۶۵.۷	۳۴.۳	۳۱.۳	۰.۹۵



شکل ۴. آنالیز برازندگی پس از آموزش

همان‌طور که ملاحظه می‌شود شبکه قادر است هر پیش‌بینی مربوط به مجموعه آزمایش را با خطای ۳/۴۸ درصد انجام دهد. به طور ملموس‌تر در هر پیش‌بینی به طور متوسط حدود ۷۰ سنت خطا دارد.

در صورت استفاده از آنالیز برازندگی پس از آموزش، جهت بررسی کیفیت مدل در قبال داده‌های آزمایش، مطابق شکل ۴ ملاحظه می‌گردد که خروجی‌های شبکه ( $X$ ) با ضریب همبستگی ۰/۹۸ به مقادیر واقعی ( $Y$ ) نزدیک است. برخی از مقادیر واقعی و پیش‌بینی شده قیمت نفت خام توسط مدل، برای سال ۲۰۰۱ در جدول ۷ ارائه گردیده است.

جدول ۷. مقایسه مقادیر واقعی و پیش‌بینی شده قیمت نفت خام برای سال ۲۰۰۱

ماه	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
واقعی	۲۴.۴۹	۲۴.۹۷	۲۳.۰۱	۲۲.۹۹	۲۴.۶۳	۲۳.۹۵	۲۲.۸۳	۲۳.۷۷	۲۲.۵۱	۱۸.۷۶	۱۶.۰۶	۱۵.۹۵
پیش‌بینی	۲۳.۲۱	۲۴.۴۶	۲۵.۰۱	۲۲	۲۳.۵۹	۲۵.۳۴	۲۳.۳۷	۲۱.۹۶	۲۴.۱۹	۲۱.۷۱	۱۷.۱۲	۱۵.۲۴

*Price Change Forecasting*”, The journal of Energy & Development, Vol. 19, 1996, No. 1.

- [3] Energy Information Administration (Online) (Cited 24 April 2003), Short Term Energy Outlook, Available from: <http://www.eia.doe.gov/meeu/steo/pub>.
- [4] Abramson, B., & Finniza, A., “*Probabilistic Forecasts From Probabilistic Models: a Case Study in The Oil Market*”, International journal of forecasting, Vol. 11, 1995, PP. 63-72.
- [5] Kaboudan, M.A., “*Comp metric Forecasting of Crude Oil Prices*”, IEEE, 2001, PP. 283-287.
- [6] Pasini, A., Vinicio, P., & Potesta, S., “*Research in Neural Meteorological Forecasting at The Italian Met Service*”, Available from: <http://www.pd.astro.it/TNG/Publications/news/16/16itav.html>
- [7] Shah, J.R., & Murtaza, M.B., “*A Neural Network Based Clustering Procedure For Bankruptcy Prediction*”, American Business Review, Jun. 2000, PP. 80-86.
- [8] Atiya, A.F., El-Shoura, S.M., Shaheen, S.I., & El-Sherif, M.S., “*A Comparison Between Neural-Network Forecasting Techniques—Case Study: River Flow Forecasting*”, IEEE Transactions On Neural Networks, Vol. 10, No.2, 1999, PP. 402-409.
- [9] Zhang, G., & Hu, M.Y., “*Neural Network Forecasting of The British Pound/US Dollar Exchange Rate*”, Omega, The International journal of management science, Vol. 26, No. 4, 1998, PP. 495-506.
- [10] Khaloozadeh, H., Khaki Sedigh, A., & Lucas, C., “*Long Term Prediction of Tehran price Index (TEPIX) Using Neural Networks*”, Proceeding of the 2nd Irano-Armenian workshop on neural networks, 2001, PP. 139-145.
- [11] Lubis, H.Y., “*Initial Public Offering Prediction Using Neural Network*”, Vol. 61, No. 11, May 2001, PP. 5963-6041.
- [12] Tkacz, G., “*Neural Network Forecasting of Canadian GDP Growth, International Journal of Forecasting*”, Vol. 17, 2001, PP. 57-69.
- [13] Ahmadian, M., “*Economics of Oil in Practice and Theory*”, tarbiat modares University, 1378.
- [14] Dargay, J., & Gately, D., “*The Imperfect Price Reversibility of Non-Transport Oil Demand in The OECD*”, Energy Economics, Vol. 17, No. 1, 1995.
- [15] Demuth, H., & Beale, M. MATLAB 6.1 / Neural Network Toolbox Version 4.0.1 (CD-ROM), The Math Works Inc., 2001, 1-844.

## ۶. نتیجه گیری

در سال‌های اخیر رویکرد شبکه‌های عصبی در حوزه پیش‌بینی بسیار مورد توجه واقع شده است. در این تحقیق رویکرد مذکور جهت پیش‌بینی قیمت ماه بعد نفت خام مورد استفاده قرار گرفت تا به کمک آن پویایی‌های فراوان قیمت نفت خام مدل شود. در فرآیند ساخت مدل برخلاف دیگر محققین که تنها از روش‌های یادگیری ساده نظیر پسانتشار خطا جهت آموزش شبکه عصبی استفاده نموده‌اند از روش‌های پیشرفته‌تر نظیر الگوریتم‌های شبه‌نیوتنی و لوبنرگ-مارکوات استفاده گردیده و بهبود فراوانی در یادگیری و قدرت پیش‌بینی شبکه حاصل گردیده است. همچنین تأثیر متغیرهای مختلف فنی و بنیادی با انجام آزمایش‌های فراوان بررسی گردیده است ولی هیچ یک از متغیرها به جز متغیر تأخیری قیمت نفت خام با وقفه‌های ۱ تا ۹ نتوانسته است نتایج پیش‌بینی شبکه را بهبود بخشد. در واقع وقفه‌های قیمت نفت به تنهایی نتوانسته است پویایی‌های سری زمانی قیمت نفت را به شبکه منتقل نماید. متغیرهای بنیادی دیگر نظیر تولید نفت خام اوپک فقط تشخیص صحیح روند قیمت‌ها را از ۶۵٪ به ۷۰٪ درصد بهبود داده است. همچنین آزمایش‌های انجام شده در این تحقیق برخلاف آزمایش‌های انجام شده توسط محققین دیگر، شبکه‌های ۲ و ۳ لایه را نیز علاوه بر شبکه تک لایه پوشش می‌دهد. در این تحقیق انواع مختلف شبکه نیز مورد آزمایش قرار گرفته و در نتیجه با استفاده از ساختار و آموزش مناسب شبکه، میانگین مربعات خطای ۰/۹۶۱ حاصل گردیده است که در مقایسه با مدل شبکه عصبی کابودان با میانگین مربعات خطای ۳/۵۴ و مدل الگوریتم ژنتیک این محقق با میانگین مربعات خطای ۱/۸۵ به ترتیب ۷۲ و ۴۸ درصد بهبود در قدرت پیش‌بینی شبکه حاصل شده است.

## ۷. تشکر و قدردانی

لازم است از آقایان Mathew Shane از بانک جهانی و Karen Freedman از سازمان مدیریت اطلاعات انرژی آمریکا به خاطر در اختیار قراردادن داده‌های مورد استفاده در این تحقیق، تشکر و قدردانی بعمل آید.

## مراجع

- [1] Nelson, Y., & Stoner, S., “*Results of The Delphi VIII Survey of Oil Price Forecasts*”, California Energy Commission, Staff Report, 1996, PP. 1-16.
- [2] Liao, H., & Lin, S., “*The Capture of Oil Price Shock-Oil*



- [20] Qi, M., & Zhang, G.P., "An Investigation of Model Selection Criteria For Neural Network Time Series Forecasting", *European Journal of Operational Research*, Vol. 132, 2001, PP. 666-680.
- [21] Yao, J., Li, Y., & Tan, C.L., "Option Price Forecasting Using Neural Networks", *Omega, The International Journal of Management Science*, Vol. 28, 2000, PP. 455-466.
- [22] Azoff, E., "Neural Network Time Series Forecasting of Financial Markets", John Wiley & Sons, 1994.
- [23] Rech, G., "Forecasting With Artificial Neural Network Models, SSE/EFI Working Paper Series in Economics and Finance", No. 491, 2002, PP. 2-4.
- [16] Wilson, I.D., Paris, S.D., Ware, J.A., & Jenkins, D.H., "Residential Property Price Time Series Forecasting With Neural Networks", *Knowledge-Based System*, Vol. 15, 2002, PP. 335-346.
- [17] Kaastra, I., & Boyd, M., "Designing A Neural Network For Forecasting Financial and Economic Time Series", *Neurocomputing*, Vol. 10, 1996, PP. 215-236.
- [18] StatSoft, Time Series Prediction in ST Neural Networks, Available from: <http://www.statsoft.com>, 2002.
- [19] Zhang, G., Patuwo, B.E., & Hu, M.Y., "Forecasting With Artificial Neural Networks: The State of The Art", *International Journal of Forecasting*, Vol. 14, 1998, PP. 35-61.