

## مطالعه تطبیقی روش‌های خطی ARIMA و غیرخطی شبکه‌های عصبی فازی در پیش‌بینی تقاضای اشتراک گاز شهری

محمدحسین پور کاظمی\*

امیر افسر\*\*

بیژن نهاوندی\*\*\*

تاریخ دریافت: ۸۴/۲/۱۲ تاریخ پذیرش: ۸۴/۴/۱۴

### چکیده

اطلاع از میزان تقاضای موجود در هر دوره یکی از مباحثی است که شرکت ملی گاز در راه پاسخگویی به مراجعان به آن نیاز دارد. عدم اطلاع از میزان تقاضای اشتراک سبب ایجاد مشکلاتی مانند عدم آگاهی از تعداد پیمانکاران مورد نیاز و همچنین فقدان برنامه کنترل موجودی مناسب برای انواع کنتورهای مورد نیاز و دیگر عوامل مرتبط می‌شود. در چند دهه گذشته، اقتصاددانان و علمای مدیریت برای برآورد تقاضا اغلب از روش‌های اقتصادسنجی استفاده کرده‌اند. امروزه از بین روش‌های پیش‌بینی، شبکه‌های عصبی مصنوعی و مدل‌های فازی در بسیاری از زمینه‌های کاربردی استفاده شده‌اند که هر کدام از آنها دارای محاسن و معایبی هستند. بنابراین، ترکیب موفقیت‌آمیز این دو روش، مدل‌سازی شبکه‌های عصبی مصنوعی و فازی، با اتکا به ترکیب قدرت یادگیری شبکه‌های عصبی و عملکرد منطقی سیستم‌های فازی تبدیل به بازار بسیار قدرتمندی شده که هم‌اکنون کاربردهای گوناگونی دارند. در این تحقیق، تقاضای اشتراک گاز شهری خانگی شهر تهران با استفاده از روش خطی  $ARIMA^1$  و روش غیرخطی شبکه‌های عصبی فازی بررسی شده و از لحاظ شش معیار ارزیابی عملکرد با یکدیگر مقایسه شده‌اند. نتایج تحقیق بیان‌گر این حقیقت است که برای پیش‌بینی تقاضای اشتراک گاز شهری، شبکه‌های عصبی فازی در تمامی شش معیار ارزیابی عملکرد، بر روش  $ARIMA$  برتری داشته، بنابر این مناسب‌تر است.

طبقه‌بندی JEL: C13، C32، C53.

**کلیدواژه:** شبکه‌های عصبی، منطق فازی،  $ARIMA$ ، روش‌های غیرخطی، پیش‌بینی، تقاضا، گاز شهری

\* دانشیار دانشگاه شهید بهشتی.

\*\* دانشجوی دانشگاه تربیت مدرس.

\*\*\* دانشجوی دانشگاه تربیت مدرس.

1- Autoregressive Integrated Moving Average.

## ۱- مقدمه

شرکت‌های فعال در بخش انرژی اغلب به صورت انحصاری عمل کرده و توسط دولت اداره می‌شوند. امروزه، گاز به عنوان یکی از مهم‌ترین بخش‌های انرژی چه در سطح داخلی و چه در سطح جهانی، مطرح است. در اهمیت این بخش می‌توان به اقبال روزافزون کشورها و حکومت‌ها به چنین سوخت‌هایی در مقابل سوخت‌های سنتی همچون نفت اشاره کرد. در کشور ما نیز با توجه به وجود ذخایر عظیم گاز و دست یابی به ذخایر جدید، اهمیت موضوع به قدری بالا رفته است که پرداختن به جنبه‌های مختلف آن ارزش فراوانی دارد.

طبق آمار به دست آمده و بررسی‌های صورت گرفته در کشور ما، در هر روز افراد زیادی متقاضی استفاده از گازند. از سوی دیگر شرکت ملی گاز بر اساس وظیفه تعریف شده خود، مسؤول پاسخگویی به این نیازهاست. یکی از مشکلاتی که شرکت ملی گاز در راه پاسخگویی به نیازهای مراجعان با آن مواجه است، عدم اطلاع دقیق از میزان تقاضای موجود در هر دوره است. لازم به ذکر است که این موضوع به نوبه خود سبب ایجاد مشکلاتی از جمله عدم آگاهی از تعداد پیمانکاران مورد نیاز و همچنین فقدان برنامه کنترل موجودی مناسب درباره انواع کنتورهای مورد نیاز، در نتیجه مجهول بودن تقاضای اشتراک از سوی مشتریان می‌شود. با توجه به مطالب فوق، هدف این تحقیق برآورد تقاضای اشتراک گاز شهری (تعداد کنتورهای گاز خانگی) و ارائه مدل مناسبی برای پیش‌بینی این تقاضا در آینده بوده است تا شرکت ملی گاز بتواند بر بسیاری از این مشکلات فائق آمده و شرایط تصمیم‌گیری را از حالتی نامطمئن به حالتی مطمئن هدایت کند. صرف نظر از تحقیقات صورت گرفته در زمینه پیش‌بینی، هدف این پژوهش، تمرکز بر توسعه روش‌های پیش‌بینی دقیق‌تر و معتبرتر است. به این منظور دو طیف روش‌های خطی و غیرخطی بررسی شده و از روش ARIMA به عنوان روش خطی و از روش شبکه‌های عصبی مصنوعی، به عنوان روش غیرخطی پیش‌بینی استفاده شده است.

## ۲- شبکه‌های عصبی، شبکه‌های عصبی فازی و پیشینه کاربرد آن

در ۲۰ سال اخیر روش‌های قابل توجهی در آزمایش و مدل‌سازی سری‌های زمانی رشد پیدا کرده است. در سال‌های اخیر بیشتر نظرات روی مدل‌های شبکه عصبی متمرکز شده است. یکی از موارد جذاب آن، فراهم‌سازی یک چارچوب بسیار عمومی و فراگیر است که هر نوع رفتار غیرخطی در داده‌ها را به تقریب مشخص می‌کند. انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق می‌توانند استفاده شوند که در این تحقیق از شبکه عصبی چند لایه پیش‌خور<sup>۱</sup> (MFNN) استفاده شده است. شبکه عصبی چند لایه پیش‌خور، مثالی از شبکه عصبی آموزش داده شده با استفاده از ناظر است. مدل‌های آموزشی با ناظر داده‌های آموزشی شامل اطلاعات کامل درباره خصوصیات داده‌ها و نتایج قابل مشاهده است. مدل‌ها می‌توانند ارتباط‌های بین این خصوصیات (ورودی‌ها) و نتایج (خروجی‌ها) را آموزش دهند. MFNN به صورت تکراری این داده‌ها را تا زمانی که یاد بگیرند چگونه این ارتباط‌ها را به صورت صحیح نشان دهند، آموزش می‌دهد.

بر طبق مطالعات اخیر<sup>۲</sup>، بیش از پنجاه درصد مطالعات کاربردی بازرگانی شبکه عصبی گزارش شده، از شبکه‌های عصبی چند لایه پیش‌خور با قوانین الگوریتم یادگیری پس‌انتشار خطا استفاده کرده‌اند. این نوع شبکه عصبی به دلیل کاربردهای گسترده در بسیاری از ابعاد مسایل مربوط به مدیریت، مانند پیش‌بینی اصولی، طبقه‌بندی و مدل‌سازی، بسیار استفاده شده است. MFNN برای حل مسایلی که شامل یادگیری ارتباط بین یک مجموعه ورودی‌ها و خروجی‌های مشخصند، مناسب است. که در حقیقت یک تکنیک آموزش با ناظر برای یادگیری ارتباط‌های بین داده‌ها با استفاده از مجموعه داده‌های آموزش است.

برای یک الگوی ورودی داده شده، شبکه، یک خروجی  $Z_k$  (یا مجموعه‌ای از خروجی‌ها) را ایجاد می‌کند و این واکنش با واکنش مطلوب هر عصب  $d_k$  (مقدار

1- Multilayered Feedforward Neural Network.

2- Wong et al., 2000.

هدف<sup>۱</sup>) مقایسه می‌شود. این مقدار برای مسایل پیش‌بینی، مقداری پیوسته است. وزن‌های شبکه سپس برای صحیح شدن یا کاهش خطا اصلاح می‌شوند و الگوی بعدی نمایان می‌شود. اصلاح وزن‌ها به‌طور پیوسته در این روال تا زمانی که کل خطاها از سطح تیرانس از پیش تعیین شده کمتر شود، ادامه پیدا می‌کند. این الگوریتم یادگیری به‌الگوریتم پس انتشار خطا<sup>۲</sup> معروف است<sup>۳</sup>. دلیل این که تأثیر این به‌روز رسانی ورودی‌ها به‌صورت تدریجی مجذور میانگین خطا (MSE) را به‌حداقل می‌رساند، اینست که تمامی الگوهای ورودی، متکی بر این حقیقتند که الگوریتم یادگیری پس انتشار خطا، گرادیان نزولی در تابع خطا دارد.

بیشتر ادبیات پیش‌بینی توسط محققانی چون ژانگ، پاتوو و هو<sup>۴</sup>، و کاربردهای اخیر توسط سوانسون و وایت، داربلی و اسلسما، کوی و تکاز<sup>۵</sup> صورت گرفته است. البته علی‌رغم قدرت و شهرت این مدل‌ها کارکرد مدل‌های شبکه عصبی در پیش‌بینی تجربی، به‌صورت ترکیبی است<sup>۶</sup>. در زمینه داده‌های اقتصادی سوانسن و وایت<sup>۷</sup>، عملکرد مدل‌های شبکه عصبی را در پیش‌بینی سری‌های زمانی اقتصاد کلان مطالعه کرده‌اند. همچنین در ایالات متحده آمریکا، مودی، لوین و ره‌فوس<sup>۸</sup> با تمرکز بر تولید ادغامی در صنعت دریافتند که مدل شبکه عصبی بر مدل خطی در افق‌های ۶ ماهه و بیشتر ارجحیت دارد. تکاز<sup>۹</sup> نشان داد که تولید ناخالص داخلی کانادا در دوره‌های یک ساله توسط شبکه عصبی بهتر از مدل‌های خطی پیش‌بینی می‌شوند. در کاربرد متفاوت دیگری، کوی<sup>۱۰</sup>، مفید بودن مدل‌های شبکه عصبی را در پیش‌بینی متغیر دودویی نشان‌دهنده بحران اقتصادی بررسی می‌کند.

با این همه، شبکه‌های عصبی مصنوعی مبتنی بر الگوریتم پس انتشار خطا، دارای برخی ضعف‌ها مانند گیر کردن شبکه در نقطه مینیمم محلی هستند و

1- Target Value.

2- Backpropagation.

3- Wrebo, 1974; Le Cun, 1985; Parker, 1985.

4- Zhang, Patuwo and Hu, 1998.

5- Darbelly and Slsma, 2000, Swanson and White, 1997, Qi, 2001, Tkacz, 2001.

6- Zhang et al., 1998.

7- Swanson and White, 1997.

8- Moody, Levin and Rehfuss, 1993.

9- Tkacz, 2001.

10- Qi, 2001.

سرعت همگرایی محاسبات اغلب پایین است که بر روایی و دقت مدل پیش‌بینی تأثیر می‌گذارد. بنابراین، محققان ترغیب شدند تا نظریه استدلال فازی را با شبکه‌های عصبی مصنوعی جهت بهبود سرعت همگرایی و دقت مدل پیش‌بینی ترکیب کنند. بنابراین، شبکه عصبی فازی بر مبنای مدل استدلال تاکاگی - سوگنو<sup>۱</sup> بهبود یافته را پیشنهاد کردند.

در نتیجه افزایش نیاز به سیستم‌های هوشمند، سیستم‌های شبکه عصبی فازی، علاقه روزافزون محققان در زمینه‌های گوناگون علمی مدیریت و مهندسی را به خود جلب کرده‌اند و در گستره وسیعی از مباحث حوزه مدیریت کاربرد دارند. تکامل فنون محاسباتی نرم، درک جنبه‌های گوناگون مساله و به‌دنبال آن، قابلیت پیش‌بینی خیلی از وقایع را افزایش داده است. مدل‌های وابسته از برخی روش‌های محاسبه عصبی، محاسبه عصبی فازی، الگوریتم‌های در حال تکامل و فنون ترکیبی متعددی استفاده می‌کنند.

شبکه‌های عصبی - فازی از دانش نظام ادراکی فازی و توانایی یادگیری آن بهره می‌برد. از این رو نظام عصبی - فازی قادر به مدل‌سازی دقیق عدم اطمینان و بی‌دقتی درونی داده‌ها به‌منظور استفاده از توانایی یادگیری شبکه‌های عصبی - فازی است. اگر چه عملکرد سیستم‌های عصبی - فازی متأثر از دامنه مساله است، اغلب در مقایسه با شبکه عصبی صرف، نتایج بهتری را ارائه می‌دهد. یکی دیگر از مزایای شبکه‌های عصبی - فازی در مقایسه با شبکه عصبی، توان استدلال آن با استفاده از قواعد منطقی در حالات خاص است.

به‌طور کلی، شبکه‌های عصبی مصنوعی برای مقصودی که ما از آن استفاده می‌کنیم، توانایی بالایی در توسعه یک مدل در زمان منطقی را ندارد. از طرف دیگر، مدل‌سازی فازی برای کاربرد ادغام تصمیمات از متغیرهای متفاوت، نیازمند یک رویکرد برای یادگیری از تجربیات (داده‌های جمع‌آوری شده) است. شبکه‌های عصبی مصنوعی و مدل فازی در بسیاری از زمینه‌های کاربردی استفاده شده‌اند و هر کدام آنها دارای محاسن و معایبی هستند. بنابراین، با ترکیب موفقیت‌آمیز این

1- Takagi-Sugeno.

دو روش، مدل‌سازی شبکه‌های عصبی مصنوعی و فازی، استفاده شده و امروزه روی آن کار می‌شود.

با ترکیب شبکه‌های عصبی و منطق فازی به یک روش آموزش ترکیبی دست پیدا کرده‌ایم که به این صورت عمل می‌کند؛ در هر دور آموزش، هنگام حرکت رو به جلو، خروجی‌های گره‌ها به صورت عادی تا لایه آخر محاسبه می‌شوند و سپس شاخص‌های نتیجه توسط روش کمترین مجموع مربعات خطا محاسبه می‌شوند. در ادامه، پس از محاسبه خطا در بازگشت رو به عقب نسبت خطا بر روی شاخص‌های شرط پخش شده و با استفاده از روش شیب نزولی خطا، مقدار آنها تصحیح می‌شود.


سیستم عصبی- فازی را می‌توان به عنوان ترکیبی از ANN و سیستم استنباط فازی (FIS) تعریف کرد. به این ترتیب الگوریتم‌های یادگیری شبکه عصبی برای تعیین شاخص‌های FIS استفاده می‌شود. یک جنبه مهم اینست که سیستم، درباره قوانین « اگرچه... آنگاه » فازی، تفسیر بیشتری ارائه دهد، زیرا بر اساس سیستم فازی، برگرداننده مفاهیم علمی مبهم<sup>۱</sup> است. ساختارهای مختلفی برای پیاده‌سازی یک سیستم فازی توسط شبکه‌های عصبی پیشنهاد شده‌اند که نمونه‌ای از آن در شکل ۱ ارائه شده است.<sup>۲</sup>

یک شبکه عصبی- فازی از پنج سطح تشکیل شده است، که عبارتند از:

- ۱- لایه ورودی<sup>۳</sup>،
- ۲- لایه فازی‌سازی<sup>۴</sup>،
- ۳- لایه قاعده مبنا<sup>۵</sup>،
- ۴- لایه خروجی فازی<sup>۶</sup> و
- ۵- لایه خروجی<sup>۷</sup>.

---

1- Vague.  
 2- Abraham and Nath (2001).  
 3- Input Layer.  
 4- Fuzzification Layer.  
 5- Rule Base Layer.  
 6- Fuzzy Outputs.  
 7- Output Layer.




همان‌طور که قبلاً اشاره شد، روش آموزش اصلی شبکه‌های عصبی فازی، روش پس انتشار خطا است. در این روش با استفاده از الگوریتم شیب نزولی خطا، مقدار خطا به سمت ورودی‌ها پخش می‌شود و شاخص‌ها تصحیح می‌شوند. این روش آموزش، همانند روش پس انتشار خطای مورد استفاده در شبکه‌های عصبی است.

شاید درباره هیچ‌یک از فنون پیش‌بینی آماری به‌اندازه مدل ARIMA بحث نشده باشد. این روش عبارتست از برازندن یک الگوی میانگین متحرک تلفیق شده با خود رگرسیون<sup>۱</sup> به مجموعه داده‌ها و به‌دست آوردن الگوی ریاضی شرطی است. یک مدل ARIMA سه جزء دارد: (۱) خود رگرسیون، (۲) مرتبه انباشتگی و (۳) میانگین متحرک. ساختمان مدل بنیادی ARIMA مشتمل بر چهار مرحله است، این مراحل عبارتند از: (۱) توجیه و شناسایی مدل، (۲) برآورد شاخص (۳) تشخیص و دریافت مدل (۴) تأیید، پیش‌بینی و منطقی بودن.

1- AutoRegressive.

### ۳- مدل سازی داده ها و ارزیابی روش ها

داده های تحقیق مربوط به تقاضای اشتراک گاز شهری خانگی در شهر تهران هستند که در فاصله تاریخی ۱۳۸۲/۱/۱ تا ۱۳۸۳/۱۰/۲۸ به صورت هفتگی جمع آوری شده اند. این داده ها به صورت سری زمانی بوده و در شکل (۲) نشان داده شده اند.



نمودار ۲- روند واقعی تقاضای اشتراک گاز شهری

در مطالعه تطبیقی روش های خطی و غیر خطی برای پیش بینی تقاضای اشتراک گاز شهری، از دو روش ARIMA به عنوان روش خطی و روش شبکه های عصبی فازی به عنوان روش غیر خطی استفاده شده است. به این منظور، توپولوژی مناسب شبکه های عصبی فازی و ARIMA بررسی شده است.

در طراحی مدل ARIMA، مقادیر مختلفی برای  $p$ ،  $d$  و  $q$  به صورت آزمایش و خطا بررسی و مقادیر ارزیابی عملکرد ( $MSE$ ,  $RMSE$ ,  $MAE$ ,  $MAPE$ ,  $NMSE$ ,  $R^2$ ) آنها مقایسه شده و بهترین مقادیر  $p$ ،  $d$  و  $q$  انتخاب شده اند که مرتبه خود رگرسیو ( $p$ )، برابر ۲، مرتبه میانگین متحرک مدل ( $q$ ) برابر ۲ و مرتبه تفاضلی مدل ( $d$ ) برابر ۱ است. مدل بندی ARIMA به شرح زیر به دست آمده است:

$$y_t = -3.379 - 0.6672y_{t-1} + 0.2792y_{t-2} + 0.5599\varepsilon_{t-1} - 0.3106\varepsilon_{t-2} \quad (1)$$

در طراحی مدل شبکه های عصبی فازی از شبکه عصبی چند لایه پیش خور (MFNN) با الگوریتم یادگیری پس انتشار خطا و سیستم استنتاج فازی سوگنو با



تابع ورودی "تفاوت دو تابع سیگموئید" و تابع خروجی خطی و برای غیرفازی کردن از تابع میانگین متحرک استفاده شد. برای طراحی نظام بهینه شبکه عصبی فازی، از طریق تغییر مداوم تعداد لایه‌ها و تعداد نرون‌های لایه‌های پنهان، توپولوژی مناسب شبکه عصبی بررسی شد و از طریق تغییر مداوم توابع عضویت مختلف و تعداد توابع عضویت، سیستم مناسب پایگاه استنتاج فازی طراحی شد. تعداد توابع عضویت استفاده شده در این تحقیق، ۳۶ تابع است و همان‌طور که اشاره شد، برای تابع ورودی از "تفاوت دو تابع سیگموئید" و برای تابع خروجی از تابع خطی و برای غیرفازی کردن از تابع میانگین متحرک استفاده شده است.


به‌طور متداول، از برخی معیارهای عملکرد برای نشان دادن چگونگی یادگیری ارتباط‌های داده‌ها در شبکه عصبی فازی استفاده می‌شود. برای مسایل پیش‌بینی، این معیارها اغلب مربوط به خطای بین خروجی‌های پیش‌بینی شده و خروجی مطلوب واقعی است. فرض کنید برای یک الگوی ورودی  $P$  (از مجموعه الگوهای  $P$ )، خروجی پیش‌بینی شده یک عصب  $Z_p$ ، خروجی واقعی  $d_p$  و میانگین مقدار خروجی واقعی در تمامی الگوها  $d$  است. جدول ۱ برخی از معیارهای عملکرد متداول برای مسایل پیش‌بینی را نشان می‌دهد. سه مورد اول از خانواده محاسبات میانگین خطای استاندارد هستند: مربع میانگین خطای استاندارد (MSE)، مربع مجذور میانگین خطا (RMSE)، و مربع میانگین خطای استاندارد نرمال شده (NMSE). خطاها برای جریمه کردن خطاهای بزرگ و برای خنثی کردن اثر مقادیر مثبت و منفی تفاوت‌ها به‌توان دو رسیده‌اند.  $R^2$  ضریب تعیین است و با NMSE ارتباط دارد و  $NMSE = 1 - R^2$ . مقدار  $R^2$  بین صفر تا یک است و مقدار یک نشان‌دهنده تطابق کامل داده‌هاست، در حالی که مقدار صفر نشان‌دهنده عملکردی است که می‌توان از استفاده میانگین مقدار خروجی واقعی  $d$  به‌عنوان مبنای پیش‌بینی‌ها انتظار داشت. دو معیار بعدی در مورد خطای مطلق هستند: میانگین قدر مطلق خطا (MAE) و میانگین قدر مطلق درصد خطا (MAPE). دیگر معیارها از قبیل ماکزیمم قدر مطلق خطا نیز، اغلب برای نشان دادن میزان عملکرد مدل به‌کار می‌روند. از آنجا که هر یک از معیارهای ارزیابی عملکرد، جنبه

خاصی را ارزیابی می‌کند، برای ارزیابی عملکرد شبکه از هر شش معیار بالا استفاده شده است. نتایج معیارهای ارزیابی عملکرد برای داده‌های آزمایش، با استفاده از روش‌های مختلف، در جدول (۱) ذکر شده است.

جدول ۱- مقادیر معیارهای ارزیابی عملکرد برای روش‌های مختلف

R <sup>2</sup>	MAE	MAPE	NMSE	MSE	RMSE	روش پیش‌بینی
۰/۹۹۹۹۹	۳/۰۲۶۷	۰/۴۸۶۴۳۹	۰/۰۰۰۰۱۰۴	۶۳/۶۶۳۱۴	۷/۹۷۸۹	شبکه‌های عصبی فازی
۰/۹۹۴۸۵	۱۳۷/۲۸۶۷	۲۰/۱۵۸۱	۰/۰۰۵۱۴۵	۳۱۵۹۳/۳۳۸	۱۷۷/۷۴۵	ARIMA (۲ و ۱ و ۲)

همان‌طور که در جدول (۱) مشاهده می‌شود، روش شبکه‌های عصبی فازی از نظر تمامی معیارهای عملکرد، بر روش ARIMA برتری دارد. مقایسه نتایج پیش‌بینی بر مبنای شبکه‌های عصبی فازی، ARIMA با مقادیر واقعی در جدول (۲) و شکل (۳) نشان داده شده است. مقادیر پیش‌بینی با شبکه‌های عصبی فازی تقریباً منطبق بر مقادیر واقعی هستند.



نمودار ۳- مقایسه نتایج پیش‌بینی بر مبنای شبکه‌های عصبی فازی و ARIMA با مقادیر واقعی

جدول ۲- مقایسه نتایج پیش‌بینی بر مبنای شبکه‌های عصبی فازی و ARIMA با مقادیر واقعی

پیش‌بینی ARIMA	پیش‌بینی عصبی فازی	واقعی	هفته	پیش‌بینی ARIMA	پیش‌بینی عصبی فازی	واقعی	هفته
۵۰۳/۰۹	۶۱۷/۳	۶۱۸	۴۴	--	۱۰۳۱/۸	۱۰۳۲	۱
۶۱۳/۷۵	۳۷۶/۶	۳۷۶	۴۵	۱۰۲۸/۶۲	۱۱۶۱/۷	۱۱۶۱	۲
۳۹۳/۱۶	۴۴۰	۴۴۰	۴۶	۱۱۲۶/۲۶	۱۳۶۸/۴	۱۳۶۹	۳
۴۲۲/۷۸	۵۹۴/۷	۵۹۶	۴۷	۱۳۳۵/۸۷	۱۲۳۳/۹	۱۲۳۴	۴
۵۱۸/۸۷	۳۳۰/۸	۳۲۹	۴۸	۱۲۵۸/۵۸	۱۶۴۹/۲	۱۶۴۹	۵
۳۶۴/۷۹	۶۰۳	۶۰۴	۴۹	۱۵۴۷/۸۳	۱۴۱۶	۱۴۱۶	۶
۵۴۰/۸۸	۷۱۵	۷۱۵	۵۰	۱۵۰۰/۸۷	۲۰۱۶	۲۰۱۶	۷
۷۲۷/۵۱	۸۱۷/۳	۸۱۷	۵۱	۱۸۴۰/۵۴	۱۸۹۱	۱۸۹۱	۸
۷۶۶/۷۹	۸۰۳/۲	۸۰۳	۵۲	۲۰۰۵/۲۳	۱۷۱۹	۱۷۱۹	۹
۸۲۶/۸۰	۱۱۱۶	۱۱۲۶	۵۳	۱۶۳۵/۲۲	۱۴۵۴	۱۴۵۴	۱۰
۱۰۴۳/۲۱	۱۰۲۵/۵	۹۹۷	۵۴	۱۵۷۴/۸۹	۱۷۰۹	۱۷۰۹	۱۱
۱۰۵۲/۰۶	۹۳۵/۴	۹۵۰	۵۵	۱۵۸۳/۷۹	۱۸۴۵/۱	۱۸۴۵	۱۲
۹۰۲/۹۷	۷۵۶	۷۵۴	۵۶	۱۹۱۱/۵۹	۱۵۸۴/۸	۱۵۸۵	۱۳
۸۲۲/۷۰	۱۱۰۵	۱۱۰۷	۵۷	۱۵۴۵/۳۱	۱۲۹۵/۱	۱۲۹۵	۱۴
۱۰۰۳/۳۰	۱۱۵۲/۶	۱۱۵۲	۵۸	۱۳۸۵/۲۱	۱۴۲۹/۹	۱۴۳۰	۱۵
۱۲۰۳/۳۶	۱۱۴۹	۱۱۴۹	۵۹	۱۳۵۴/۶۱	۱۲۲۰/۱	۱۲۲۰	۱۶
۱۰۸۴/۹۷	۸۸۷/۹	۸۸۸	۶۰	۱۳۱۰/۷۴	۱۳۶۳	۱۳۶۳	۱۷
۹۷۳/۰۶	۱۰۴۵/۸	۱۰۴۶	۶۱	۱۲۷۲/۶۲	۱۱۰۷	۱۱۰۷	۱۸
۹۶۱/۴۰	۱۲۰۲/۱	۱۲۰۲	۶۲	۱۲۱۲/۴۸	۸۱۱/۹	۸۱۲	۱۹
۱۲۳۷/۳۷	۱۱۱۳	۱۱۱۳	۶۳	۷۸۰/۰۶	۵۹۸/۳	۵۹۸	۲۰
۱۰۷۳/۰۹	۵۸۰/۶	۵۸۰	۶۴	۶۸۵/۲۹	۷۲۳/۷	۷۲۳	۲۱
۶۹۳/۲۸	۷۱۷/۴	۷۱۸	۶۵	۶۵۹/۳۳	۷۵۹/۴	۷۴۱	۲۲
۶۳۸/۱۹	۵۸۱/۷	۵۸۲	۶۶	۷۹۵/۴۸	۷۹۱/۵	۸۰۱	۲۳
۶۷۰/۲۵	۴۷۲/۸	۴۴۹	۶۷	۷۳۵/۹۶	۸۱۹/۵	۸۱۹	۲۴
۳۹۹/۷۱	۴۴۴/۱	۴۹۱	۶۸	۸۵۹/۶۷	۹۳۱/۶	۹۳۲	۲۵
۵۳۶/۴۳	۴۱۷/۶	۳۹۴	۶۹	۸۶۸/۰۳	۸۸۲/۳	۸۷۴	۲۶
۳۶۴/۷۷	۵۷۰/۸	۵۷۱	۷۰	۹۲۰/۱۴	۹۹۱	۱۰۰۸	۲۷
۵۷۰/۵۳	۵۹۶/۵	۵۹۷	۷۱	۹۴۰/۶۵	۱۱۰۰/۴	۱۰۹۱	۲۸
۵۷۳/۸۲	۵۱۰/۶	۵۱۰	۷۲	۱۱۱۷/۷۱	۱۱۴۶/۴	۱۱۴۷	۲۹
۵۲۹/۸۵	۵۶۵	۵۶۵	۷۳	۱۰۹۶/۳۵	۱۰۳۱/۸	۱۰۳۲	۳۰
۵۳۷/۰۷	۵۵۵/۱	۵۵۶	۷۴	۱۰۷۷/۷۶	۸۴۹/۲	۸۴۹	۳۱
۵۷۱/۴۱	۴۳۳	۴۳۲	۷۵	۸۳۷/۶۴	۸۹۵	۸۹۵	۳۲
۴۳۰/۵۶	۵۵۹/۸	۵۶۲	۷۶	۹۰۸/۸۳	۶۶۴/۶	۶۶۵	۳۳
۵۴۶/۲۸	۵۷۴/۲	۵۷۰	۷۷	۶۸۴/۴۶	۳۶۲/۴	۳۶۲	۳۴
۵۶۷/۵۴	۵۸۰/۷	۵۸۳	۷۸	۴۰۶/۵۷	۳۰۲/۱	۳۰۳	۳۵
۵۷۲/۳۹	۵۹۶/۲	۵۹۶	۷۹	۳۰۰/۴۳	۳۱۴/۶	۳۱۵	۳۶
۵۹۳/۵۰	۵۶۳/۹	۵۶۴	۸۰	۳۲۵/۴۳	۳۰۲/۳	۳۰۲	۳۷
۵۶۱/۹۱	۵۴۶/۶	۵۴۶	۸۱	۲۹۲/۸۶	۲۴۲/۹	۲۴۴	۳۸
۵۴۵/۴۴	۶۰۰/۲	۶۰۱	۸۲	۲۵۶/۷۴	۱۵۹/۲	۱۵۹	۳۹
۵۸۷/۸۶	۴۴۶/۹	۴۴۵	۸۳	۱۶۰/۱۷	۱۹۵/۸	۱۹۶	۴۰
۴۶۹/۶۴	۶۴۲/۳	۶۴۴	۸۴	۱۹۱/۵۲	۱۳۱/۲	۱۳۱	۴۱
۵۹۶/۲۶	۵۰۸/۱	۵۰۶	۸۵	۱۳۸/۰۲	۱۹۱/۸	۱۹۲	۴۲
۵۴۸/۷۶	۷۷۱	۷۷۳	۸۶	۱۷۴/۷۹	۵۵۶/۱	۵۵۶	۴۳

با توجه به این که شبکه‌های عصبی فازی نسبت به روش ARIMA در هر شش معیار ارزیابی عملکرد برتری دارد، از این روش برای پیش‌بینی تقاضای اشتراک برای ماه آینده (۴ هفته آتی) استفاده می‌شود. مقادیر پیش‌بینی برای این مدت در جدول (۳) نشان داده شده است.

جدول ۳- پیش‌بینی تقاضای اشتراک برای ماه آتی بر مبنای شبکه‌های عصبی فازی

پیش‌بینی عصبی فازی	هفته
۸۰۱/۹۴۵	۱
۸۲۷/۹۰۲	۲
۸۵۳/۸۵۶	۳
۸۷۹/۸۰۹	۴

#### ۴- نتیجه‌گیری

هدف این تحقیق برآورد تقاضای اشتراک گاز شهری و ارائه مدل مناسبی برای پیش‌بینی این تقاضا در آینده است تا شرکت ملی گاز بتواند بر بسیاری از این مشکلات فائق آمده و شرایط تصمیم‌گیری را از حالتی نامطمئن به حالتی مطمئن تبدیل کند. صرف نظر از تحقیقات صورت گرفته در زمینه پیش‌بینی، هدف این تحقیق تمرکز بر توسعه روش‌های پیش‌بینی دقیق‌تر و معتبرتر است. به این منظور دو طیف روش‌های خطی و غیرخطی بررسی شده‌اند و از روش ARIMA به عنوان روش خطی و از روش شبکه‌های عصبی مصنوعی، به عنوان روش غیرخطی پیش‌بینی استفاده شده و از لحاظ شش معیار عملکرد MSE، RMSE، NMSE، MAE، MAPE و  $R^2$  با هم مقایسه شدند. نتایج تحقیق نشان‌گر آنست که شبکه‌های عصبی فازی از لحاظ تمامی معیارهای عملکرد بر روش ARIMA برتری دارد. نتایج تجربی این تحقیق و تحقیقات مشابه نشان داده‌اند که ترکیب شبکه‌های عصبی مصنوعی و منطق فازی و ایجاد شبکه‌های عصبی فازی موفقیت‌آمیز بوده و باعث کاهش قابل توجه در خطای پیش‌بینی شده است که خصیصه‌های قابل توجهی در همگرایی سریع، دقت بالا و توانایی تقریب تابع قوی

دارد. علاوه بر این، از آنجا که سیستم شبکه‌های عصبی فازی نیازمند داده‌های صریح و قطعی نبوده و نمونه بزرگی از داده‌ها را نیاز ندارد، می‌تواند پیش‌بینی خوبی از شاخص قیمت سهام ارائه دهد و اطمینان می‌دهد که این روش نسبت به روش‌های کلاسیک پیش‌بینی مناسب‌تر است.

### فهرست منابع

- 1- Abraham, Ajith and Nath, Baikunth, (2001), "A neuro-fuzzy approach for modelling electricity demand in Victoria", *Applied Soft Computing*, 1 127-138.
- 2- Darbellay, G. A., & Slama, M., (2000), "Forecasting the short-term demand for electricity: do neural networks stand a better chance", *International Journal of Forecasting*, 16 71- 83.
- 3- Desai, V.S.& Bharati,R., (1998), "A comparison of linear regression and neural network methods for predicting excess returns on large stocks", *Annals of Operations Research*, 78 127-163.
- 4- Dhar,V.& chou,D., (2001), "A comparison of nonlinear methods for predicting earnings surprises and returns", *IEEE Transactions on Neural networks*, 12(4) 907-921.
- 5- Heravi, Saeed, Osborn, Denise R. and Birchenhall, C.R., (2004), "Linear versus neural network forecasts for European industrial production series", *International Journal of Forecasting*, 20 435- 446.
- 6- J.M. Zurada, (1992), "Introduction to Artificial Neural Systems", PWS Pub Co, .
- 7- Jang, J. R. and Sun, C., (1995), "Nero Fuzzy Modelling and Control", *Proc. of the IEEE*, 78-405.
- 8- Kuo, R.J., Chen, C.H. and Hwang, Y.C., (2001), "An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network", *Fuzzy Sets and Systems*, 118.
- 9- Leung,M.T., Daouk, H.,& Chen, A.-S., (2001), "Forecasting stock indices: A comparison of classification and level estimation models", *International Journal of Forecasting*, 16, 173-190
- 10- Moody, J., Levin, U., & Reh fuss, S., (1993) "Predicting the US index of industrial production", *Neural Network World*, 3 791-794.
- 11- Qi, M., (2001), "Predicting US recessions with leading indicators and neural network models", *International Journal of Forecasting*, 17 383-401.
- 12- Qi,M., (1999), "Nonlinear predictability of stock returns using financial and economic variables", *Journal of Business & Economic Statistics*,

- 17(4) 419-429.
- 13- Qi, M., (2001), Predicting US recessions with leading indicators via neural network models. *International Journal of Forecasting*, 17(3) 383-401.
  - 14- Swanson, N. R., & White, H., (1997a), "A model selection approach to real time macroeconomic forecasting using linear models and artificial neural networks", *Review of Economics and Statistics*, 39 540– 550.
  - 15- Swanson, N. R., & White, H., (1997b), "Forecasting economic time series using adaptive versus nonadaptive and linear versus nonlinear econometric models", *International Journal of Forecasting*, 13 439–461.
  - 16- Tkacz, G., (2001), "Neural network forecasting of Canadian GDP growth", *International Journal of Forecasting*, 17 57–69.
  - 17- Tong, R. M., (1997), "A control engineering review of fuzzy systems", *Automatic*, 13(6) 559-569.
  - 18- Wang, L. X., Mendel J. M., (1992), "Fuzzy basis functions, universal approximation and orthogonal least-squares learning", *IEEE Transaction on Neural Networks*, 807-814.
  - 19- Wang, J.-H. & Leu, J.-Y., (1996), "Stock market Trend Prediction using ARIMA-based neural networks", *IEEE international Conference on Neural networks*, 2160-2165.
  - 20- Wittkemper, H. & Steiner, M., (1996), "Using neural networks to forecast the systematic risk of stocks", *European Journal of Operational research*, 577-588.
  - 21- Wong, B.K., Jiang, L. and Lam, J., (2000), "A bibliography of neural network business application research: 1994-1998". *Computers and Operations Research*, 27(11) 1045-1076.
  - 22- Zadeh, L.A., (1973), "Outline of a new approach to the analysis of complex systems and decision processes", *IEEE Trans. Systems Man Cybernet*, SMC-3 (1) 28-44.
  - 23- Zhang, G., Patuwo, B. E., & Hu, M. Y., (1998), "Forecasting with artificial neural networks: the state of the art", *International Journal of Forecasting*, 14 35- 62.
  - 24- Zimmermann, M. J., (1996), "Fuzzy Set Theory and its application", Kluwer Academic Publishers, Boston.