

پیش بینی صادرات غیر نفتی ایران: الگوهای رگرسیونی و شبکه عصبی مصنوعی

رضا مقدسی*، پریسا خلیق خیاوی**، محمد کاوسی کلاشمی***

تاریخ دریافت: ۹۰/۰۴/۳۰ تاریخ پذیرش: ۹۰/۷/۱۲

چکیده

در نوشتار حاضر از الگوهای شبکه عصبی مصنوعی و SARIMA برای پیش بینی مقادیر صادرات غیرنفتی ایران استفاده شده است. برای این منظور سری زمانی ماهیانه ارزش صادرات غیرنفتی طی سال‌های ۱۳۸۰ تا ۱۳۸۸ مورد استفاده قرار گرفته است. مقایسه قدرت پیش بینی دو الگوی فوق به کمک معیارهای خطای میانگین، ریشه دوم میانگین خطا، میانگین خطای مطلق، میانگین درصد خطا و میانگین درصد خطای مطلق انجام شد. مقدار MAPE برابر با ۰/۴۴ درصد نشان دهنده برتری شبکه عصبی مصنوعی در پیش بینی صادرات غیرنفتی در قیاس با الگوی فصلی SARIMA است.

طبقه‌بندی JEL: F17، C53، C45.

واژگان کلیدی: الگوی شبکه عصبی مصنوعی، الگوی SARIMA، فراوانی غیرفصلی و فصلی، صادرات غیرنفتی، ایران.

* دانشیار دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، گروه اقتصاد کشاورزی، تهران، ایران (نویسنده مسئول)، پست الکترونیکی: r.moghaddasi@sbiau.ac.ir

** دانشجوی دوره دکتری اقتصاد کشاورزی واحد علوم و تحقیقات

*** دانشجوی دکتری اقتصاد کشاورزی دانشگاه تهران

۱- مقدمه

فروش نفت و مواد نفتی و درآمدهای حاصل از آن همواره دستخوش تغییر و ناپایداری بوده است. لذا به دلیل تکیه اقتصاد ایران به درآمدهای حاصل از فروش نفت خام و محدود بودن ذخایر نفتی و بنابراین به منظور کاهش وابستگی اقتصاد ایران به صادرات نفت خام و چرخش به سمت اقتصاد چند محصولی در صادرات، جهت‌گیری سیاست‌های صادراتی باید به سود صدور کالاهای غیر نفتی تغییر یابد. چنین امری تحقق پیدا نمی‌کند مگر اینکه فرصت‌های موجود در صادرات غیرنفتی شناسایی و به این فرصت‌ها جنبه عملیاتی بخشیده شود (ابریشمی و همکاران، ۱۳۸۸). توسعه صادرات غیرنفتی، علاوه بر اینکه سبب افزایش درآمدهای ارزی و بهبود ترازپرداخت‌های ارزی می‌شود، می‌تواند تاثیر زیادی بر اشتغال در کشور بگذارد. اما واقعیت این است که در ایران معمولاً یکسری سیاست‌های تشویقی و کوتاه مدت نظیر کاهش و یا حذف تعرفه‌های صادراتی، اعطای جوایز صادراتی و ... اجرا می‌شود که در کوتاه مدت موجب افزایش صادرات غیر نفتی می‌شود. اما باید توجه داشت که در جهت رشد و توسعه صادرات غیرنفتی در بلند مدت باید سیاست‌گذاری‌های پایه‌ای و بنیادی صورت گیرد (مهدوی عادل و همکاران، ۱۳۸۸).

هدفمند کردن یارانه‌ها باعث می‌شود تولیدکنندگان ما به دنبال بالابردن بهره‌وری خود و استفاده از تکنولوژی‌های نوین باشند که این موضوع منجر به تولید کالاهایی هماهنگ با تکنولوژی روز، علم روز، کیفیت برتر، بهره‌وری بیشتر، قیمت کم و امکان رقابت در بازارهای بین‌المللی می‌شود. لذا هدفمند کردن یارانه‌ها منافع اقتصادی زیادی را به خصوص در صادرات غیر نفتی به دنبال دارد (وزارت بازرگانی، ۱۳۸۸).

بررسی هدف‌گذاری و تحقق صادرات غیرنفتی در برنامه‌های توسعه ایران طی سال‌های ۸۸-۱۳۶۸ نشان می‌دهد که درصد تحقق صادرات غیر نفتی طی چهار برنامه اول توسعه به ترتیب برابر با ۶۶، ۵۸، ۹۲ و ۱۴۹ درصد می‌باشد. لذا در برنامه چهارم توسعه اقتصادی و اجتماعی بیش از هدف‌گذاری صورت گرفته عملکرد وجود داشته است به طوری که هدف صادرات غیر نفتی در برنامه چهارم ۵۲/۹ میلیارد دلار بوده ولی در طول این برنامه ۷۹ میلیارد دلار صادرات غیر نفتی صورت گرفته است.

هم چنین بررسی روند عملکرد صادرات غیرنفتی کشور با و بدون میعانات گازی به تفکیک طی سال‌های ۸۸-۱۳۸۴ در طول برنامه چهارم توسعه نشان می‌دهد که بیشترین درصد تحقق صادرات غیرنفتی با احتساب میعانات گازی مربوط به سال ۱۳۸۷ برابر با ۲۰۱ درصد و کم‌ترین مربوط به سال ۱۳۸۴ برابر با ۱۲۹ درصد می‌باشد. هم چنین بیشترین درصد تحقق صادرات غیر نفتی بدون احتساب میعانات گازی مربوط به سال ۱۳۸۸ برابر با ۱۶۶/۴ درصد و کم‌ترین مربوط به سال ۱۳۸۴ برابر با ۱۲۹ درصد می‌باشد.

۲- ادبیات موضوع

تا کنون مطالعات متعددی در زمینه پیش‌بینی متغیرهای اقتصادی انجام شده است: فرج زاده و شاه ولی (۱۳۸۸)، قیمت برخی محصولات کشاورزی را با روشهای مختلف پیش‌بینی کردند. نتایج نشان داد که الگوی ARIMA سریهای قیمت اسمی برنج و زعفران را بهتر از سایر روشها پیش‌بینی می‌کند. بهترین پیش‌بینی برای سریهای قیمت اسمی و واقعی پنبه نیز به ترتیب با استفاده از الگوهای شبکه عصبی مصنوعی و هارمونیک به دست آمد. مهربابی بشرآبادی و کوچک زاده (۱۳۸۸) جهت پیش‌بینی صادرات محصولات کشاورزی سال ۱۳۸۶ از روشهای شبکه‌های عصبی مصنوعی و ARIMA استفاده کردند. نتایج مطالعه نشان داد که شبکه‌های عصبی عملکرد بهتری در مقایسه با شبکه‌های عصبی پیش‌خور چند لایه و مدل ARIMA داشته است. قهرمان زاده و سلامی (۱۳۸۷) قیمت گوشت مرغ در استان تهران را با استفاده از تکنیک‌های سری زمانی در قالب الگوهای خود توضیحی دوره ای (PAR)، پایه رگرسیونی بر پایه آزمون‌های ریشه واحد فصلی و باکس-جنکینز (SARIMA) پیش‌بینی کردند. نتایج آزمون ریشه واحد فصلی بیانگر آن است که قیمت ماهانه گوشت مرغ از فرآیند تصادفی نایستا فصلی تبعیت می‌نماید و بر این اساس بکارگیری مدل پایه رگرسیونی برای تدوین الگوی پیش‌بینی قیمت مناسب است. شریفان و قهرمان (۱۳۸۶) مناسب ترین مدل برآورد باران را با استفاده از داده‌های روزانه و ماهانه بوسیله مدل پیش‌بینی SARIMA در استان گلستان تعیین کردند. نتایج نشان داد برای پیش‌بینی باران فقط در

مقیاس ۱۰ روزه استفاده از باران‌های ۱۰ روزه و در مقیاس ماهانه و سالانه روش استفاده از داده‌های ماهانه از دقت بیشتری برخوردار هستند.

آذر و افسر (۱۳۸۵) در تحقیقی، از مدل شبکه‌های عصبی و ARIMA برای پیش بینی قیمت سهام استفاده کردند و نتایج نشان داده که شبکه عصبی مصنوعی دارای ویژگیهای منحصر به فرد همگرایی سریع، دقت بالا، و توانایی تقریب تابع قوی هستند و برای پیش بینی شاخص قیمت مناسب می‌باشند.

سینایی و همکاران (۱۳۸۴) در مقاله‌ای به مطالعه پیش بینی شاخص قیمت سهام در بورس اوراق بهادار تهران بوسیله شبکه‌های عصبی و مدل خطی ARIMA پرداختند. نتایج حاصل از پژوهش نشان می‌دهد که شبکه‌های عصبی عملکرد بهتری نسبت به مدل خطی ARIMA برای پیش بینی شاخص قیمت دارند. فلاحی و همکاران (۱۳۸۴) جهت الگوسازی غیر خطی و پیش بینی درآمدهای مالیات بر مشاغل در اقتصاد ایران از شبکه‌های عصبی مصنوعی استفاده کرده و نتایج آن را با الگوهای رگرسیون خطی و سری زمانی مقایسه کردند. نتایج برآورد الگوها نشان‌دهنده عملکرد بهتر الگوی شبکه عصبی مصنوعی می‌باشد. قدیمی و مشیری (۱۳۸۱) کارایی مدل شبکه عصبی را با یک مدل خطی رگرسیون برای پیش بینی نرخ رشد اقتصادی در ایران مقایسه کردند. نتایج نشان داد که مدل شبکه عصبی برای پیش بینی نرخ رشد اقتصادی در ایران از کارایی بالاتری برخوردار است. مشیری (۱۳۸۰) در تحقیقی یک مدل شبکه عصبی برای پیش بینی تورم در ایران با استفاده از اطلاعات سالهای ۱۳۳۸-۱۳۷۷ طراحی و اجرا کردند. نتایج بدست آمده حاکی از آن است که مدل‌های شبکه‌های عصبی در غالب موارد عملکرد بهتری در زمینه پیش بینی تورم دوره آتی ایران نسبت به رقبای خود دارند.

لیشو وانگ و همکاران (۲۰۰۶) برای پیش بینی بازده سویا از الگوی شبکه عصبی مصنوعی هاپفیلد استفاده کردند. نتیجه تحقیق نشان داده که دقت پیش بینی بازدهی سویا با این مدل نسبت به روش‌های سنتی افزایش یافته است.

فانگ می‌تسنگ، هسائو چنگ یو و گو هسیونگ تزنگ (۲۰۰۲) جهت پیش بینی دو سری زمانی فصلی کل ارزش تولید صنعت ماشین آلات تایوان و نوشیدنی‌های غیر الکلی از یک مدل پیش بینی ترکیبی از سریهای زمانی فصلی ARIMA (SARIMA) و

مدل پس انتشار شبکه مصنوعی (SARIMABP) استفاده کردند. کارایی فرآیند پیش‌بینی بین مدل‌های SARIMA، SARIMABP و شبکه مصنوعی مقایسه شد. نتایج نشان داد مدل SARIMABP نسبت به دو مدل دیگر عملکرد بهتری داشت. احمد.ا.چ.ا و همکاران (۲۰۰۱) برای پیش‌بینی قیمت تخم مرغ از روش‌های مختلف استفاده کردند نتایج حاصل از تحقیق نشان داده که پیش‌بینی با استفاده از شبکه عصبی مصنوعی نسبت به تکنیک‌های سنتی و رگرسیون‌های خطی دارای دقت بیشتر و کارایی بالاتری است.

۳- روش شناسی

داده‌های سری زمانی ماهیانه صادرات غیرنفتی ایران اطلاعات ارزشمندی را در جهت پیش‌بینی مقادیر آتی فراهم آورده و پارامترهای اصلی در تعیین مقادیر مورد نظر از قبیل روند، اثرات فصلی و شوک‌ها را در اختیار برنامه‌ریزان و محققان قرار می‌دهد. در این مطالعه جهت پیش‌بینی میزان صادرات غیر نفتی از الگوهای شبکه‌های عصبی مصنوعی^۱ و الگوی SARIMA استفاده و سپس قدرت و دقت پیش‌بینی هر یک از آنها ارزیابی می‌شود. در ادامه الگوهای مورد استفاده در این مطالعه به تفکیک بررسی خواهد شد.

۳-۱ الگوی میانگین متحرک هم‌انباشته خودتوضیحی فصلی^۲ (SARIMA)

الگوی میانگین متحرک هم‌انباشته خودتوضیحی فصلی بسط الگوی میانگین متحرک هم‌انباشته خودتوضیحی (ARIMA) می‌باشد. الگوی ARIMA مقادیر گذشته سری زمانی را برای پیش‌بینی مقادیر آتی سری زمانی مورد استفاده قرار می‌دهد. (Zeileis, ۲۰۰۸).

سری زمانی ماهیانه صادرات غیرنفتی^۳ ایران NPE_t را $ARIMA(p,d,q)$ نامیده که در آن p ، تعداد وقفه‌های خودتوضیحی، d درجه انباشتگی به منظور ایستا نمودن داده و q تعداد وقفه‌های میانگین متحرک الگو می‌باشد، اگر $NPE_t = (1-L)^d NPE_t$ به صورت

1- Artificial Neural Network(ANN)
2- Seasonal AutoRegressive Integrated Moving Average
3- Non-Petroleum Export

ARMA (p,q) باشد. به طور کلی، رابطه فوق را می‌توان به صورت زیر نوشت (Enders, ۱۹۹۵):

$$\phi(L)(1-L)^d NPE_t = \theta(L)\varepsilon_t \quad (1)$$

در رابطه فوق، ε_t ویژگی فرآیند نوفه سفید^۱ (NPE) را دارا می‌باشد. عملگر وقفه^۲ را نیز می‌توان به صورت $L^k NPE_t = NPE_{t-k}$ تعریف نمود، از سوی دیگر، دو عملگر خودتوضیحی^۳ و میانگین متحرک^۴ به صورت زیر بیان می‌شود (Pfaff, ۲۰۰۸):

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p \quad (2)$$

$$\theta(L) = 1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q \quad (3)$$

در فرآیند فوق، $\phi(L) \neq 0$ بوده و $|\phi| < 1$ می‌باشد. بسط الگوی ARIMA به SARIMA زمانی ضرورت داشته که سری زمانی دارای هر دو رفتار فصلی^۵ و غیرفصلی^۶ باشد. وجود چنین رفتاری الگوی ARIMA را ناکارآمد نموده، زیرا در این حالت الگو تنها قادر به سنجش رفتار حول بخش فصلی سری زمانی بوده و منجر به انتخاب درجه نادرست برای جزء غیرفصلی می‌شود (Eric, ۲۰۱۰). اغلب الگوی SARIMA را میانگین متحرک هم‌انباشته خودتوضیحی فصلی فزاینده^۷ نامیده و برای سری زمانی ماهیانه صادرات غیرنفتی ایران با $(P,D,Q)_S$ NPE (p,d,q) ARIMA نشان می‌دهند. فرم کلی الگوی SARIMA برای سری زمانی ماهیانه صادرات غیرنفتی ایران به صورت زیر است:

$$\phi(L)\Phi(L^S)(1-L)^d(1-L^S)^D NPE_t = \theta(L)\Theta(L^S)\varepsilon_t$$

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$$

$$\Phi(L^S) = 1 - \Phi_1 L^S - \Phi_2 L^{2S} - \dots - \Phi_p L^{pS} \quad (4)$$

$$\theta(L) = 1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q$$

$$\Theta(L^S) = 1 + \Theta_1 L^S + \Theta_2 L^{2S} + \dots + \Theta_q L^{qS}$$

در الگوی فوق، p، d و q به ترتیب درجه خودتوضیحی، تفاضل‌گیری و میانگین

1- White Noise
 2- Lag Operator
 3- Autoregressive Operator
 4- Moving Average Operator
 5- Seasonal
 6- Non-seasonal
 7- Multiplicative Seasonal AutoRegressive Integrated Moving Average

متحرک غیر فصلی بوده و D, P و Q به ترتیب درجه خودتوضیحی، تفاضل‌گیری و میانگین متحرک فصلی می‌باشد. جزء ε_t جمله خطای دارای شرایط نوفه سفید (شوک تصادفی) و S درجه فصلی (برای داده‌های ماهیانه برابر با ۱۲) را نشان می‌دهد. به منظور برآورد الگو، در گام نخست باید ایستایی^۱ سری زمانی را مورد بررسی قرار داد. به منظور انجام آزمون ایستایی برای سری زمانی دارای رفتار فصلی و غیر فصلی، آزمون مورد استفاده باید در بردارنده اجزاء فصلی و غیر فصلی باشند. در این راستا از آزمون-های آماری چون، HEGY, CH, BM, FH, Taylor می‌توان استفاده نمود (Canova و Hansen, ۱۹۹۵؛ Franses و Hobijn, ۱۹۹۷؛ Taylor, ۱۹۹۷).

در رهیافت HEGY برای آزمون ریشه واحد سری زمانی ماهیانه، الگوی خودتوضیحی ایجاد شده، به نحوی که ریشه‌های واحد فصلی و بلندمدت توسط ضرایب رگرسیون این الگو معرفی شود. الگوی خودتوضیحی مذکور دارای فرم کلی $A(L)y_t = \varepsilon_t$ بوده، که در آن ε_t نوفه سفید و $A(L)$ عملگر وقفه از درجه دوازده می‌باشد. فرآیند فوق در صورتی ایستا بوده که تمامی ریشه‌های چندجمله‌ای $A(L)$ خارج از دایره واحد قرار گیرند. برای آزمون ریشه واحد الگوی فوق، بسط چندجمله‌ای $A(L)$ $1-L^{12}$ = مورد استفاده قرار خواهد گرفت. تجزیه سری زمانی ماهیانه برای تعیین ریشه-های واحد با استفاده از رابطه زیر صورت می‌گیرد (Franses, ۱۹۹۱):

$$\Delta_{12} = (1-L)(1+L)(1+L^2)(1+L+L^2)(1-L+L^2)(1+\sqrt{3}L+L^2)(1-\sqrt{3}L+L^2)$$

براین اساس، ریشه‌های واحد غیر فصلی و فصلی ماهیانه به ترتیب از چپ به راست به قرار زیر است:

$$\pm 1, \pm i, -\frac{1}{2}(\sqrt{3} \pm i), \frac{1}{2}(\sqrt{3} \pm i), -\frac{1}{2}(1 \pm i\sqrt{3}), \frac{1}{2}(1 \pm i\sqrt{3}) \quad (6)$$

ریشه‌های فوق به ترتیب مربوط به چرخه‌های $\infty, 6, 3, 9, 8, 4, 2, 10, 7, 5, 1$ و ۱۱ در هر سال بوده و فراوانی آنها به ترتیب عبارت از $0, \pi, \pm\pi/2, \pm 2\pi/3$ است (Beaulieu و Miron, ۱۹۹۳). به منظور انجام آزمون ریشه واحد داده‌های ماهیانه، تشکیل آزمون فرضیه باید بر مبنای بررسی وجود هر یک از ریشه‌های واحد بدون توجه به وجود یا عدم وجود سایر ریشه‌ها، صورت

1- Stationary

گیرد. در این راستا، با استفاده از تقریب تیلور^۱ تبدیل‌های خطی از سری زمانی ماهیانه مورد بررسی ایجاد شده که امکان آزمون وجود هر ریشه واحد را بدون توجه به وجود یا عدم وجود سایر ریشه‌ها فراهم می‌آورد (Franses, ۱۹۹۱). در این راستا، با استفاده از رهیافت Franses و Hobijn (۱۹۹۷) شکل کلی این آزمون برای داده‌های ماهیانه سری زمانی صادرات غیرنفتی ایران به صورت زیر است:

$$\Delta_{12}NPE_t = \alpha + \beta T + \sum_{s=1}^{11} \delta_s D_{s,t} + \pi_1 y_{1,t-1} + \pi_2 y_{2,t-1} + \pi_3 y_{3,t-1} + \pi_4 y_{3,t-2} + \pi_5 y_{4,t-1} + \pi_6 y_{4,t-2} + \pi_7 y_{5,t-1} + \pi_8 y_{5,t-2} + \pi_9 y_{6,t-1} + \pi_{10} y_{6,t-2} + \pi_{11} y_{7,t-1} + \pi_{12} y_{7,t-2} + \sum_{i=1}^p \lambda_i \Delta_{12}NPE_{t-i} + \varepsilon_t \quad (V)$$

در رابطه فوق، اجزاء قطعی شامل عرض از مبدا (α)، متغیرهای موهومی ماهیانه (D) و روند (T) می‌باشد. معادله تبدیل‌های خطی را نیز می‌توان به صورت زیر نشان داد:

داد:

(۸)

$$\begin{aligned} y_{1,t} &= (1+L)(1+L^2)(1+L^4+L^8)NPE_t \\ &= (1+L+L^2+L^3+L^4+L^5+L^6+L^7+L^8+L^9+L^{10}+L^{11})NPE_t \\ y_{2,t} &= -(1-L)(1+L^2)(1+L^4+L^8)NPE_t \\ &= (-1+L-L^2+L^3-L^4+L^5-L^6+L^7-L^8+L^9-L^{10}+L^{11})NPE_t \\ y_{3,t} &= -(1-L^2)(1+L^4+L^8)NPE_t \\ &= (-1+L^2-L^4+L^6-L^8+L^{10})NPE_t \\ y_{4,t} &= -(1-L^4)(1-\sqrt{3}L+L^2)(1+L^2+L^4)NPE_t \\ &= (-1+\sqrt{3}L-2L^2+\sqrt{3}L^3-L^4+L^6-\sqrt{3}L^7+2L^8-\sqrt{3}L^9+L^{10})NPE_t \\ y_{5,t} &= -(1-L^4)(1+\sqrt{3}L+L^2)(1+L^2+L^4)NPE_t \\ &= (-1-\sqrt{3}L-2L^2-\sqrt{3}L^3-L^4+L^6+\sqrt{3}L^7+2L^8+\sqrt{3}L^9+L^{10})NPE_t \\ y_{6,t} &= -(1-L^4)(1-L^2+L^4)(1-L+L^2)NPE_t \\ &= (-1+L-L^3+L^4-L^6+L^7-L^9+L^{10})NPE_t \\ y_{6,t} &= -(1-L^4)(1-L^2+L^4)(1+L+L^2)NPE_t \\ &= (-1-L+L^3+L^4-L^6-L^7+L^9+L^{10})NPE_t \end{aligned}$$

1- Taylor Approximation

در رابطه (۷) وارد کردن وقفه‌های متغیر وابسته باید تا جایی صورت گیرد که خصوصیت نوفه سفید جزء اخلال برقرار شود. پس از تشکیل روابط فوق و به دست آوردن ضرایب رگرسیون، به منظور تعیین وجود هر یک از ریشه‌های غیرفصلی و فصلی آزمون فرضیه‌های زیر مدنظر قرار گرفت:

- 1) $H_0 : \pi_1 = 0, H_1 : \pi_1 < 0$
- 2) $H_0 : \pi_2 = 0, H_1 : \pi_2 < 0$
- 3) $H_0 : \pi_3 = \pi_4 = 0, H_1 : \pi_3 \neq 0, \pi_4 \neq 0$
- 4) $H_0 : \pi_5 = \pi_6 = 0, H_1 : \pi_5 \neq 0, \pi_6 \neq 0$
- 5) $H_0 : \pi_7 = \pi_8 = 0, H_1 : \pi_7 \neq 0, \pi_8 \neq 0$
- 6) $H_0 : \pi_9 = \pi_{10} = 0, H_1 : \pi_9 \neq 0, \pi_{10} \neq 0$
- 7) $H_0 : \pi_{11} = \pi_{12} = 0, H_1 : \pi_{11} \neq 0, \pi_{12} \neq 0$

آماره t برای آزمون آماری وجود ریشه‌های ۱ و ۲ و آزمون F برای تعیین وجود ریشه‌های ۳، ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱ و ۱۲ مورد استفاده قرار خواهد گرفت. نتایج آماره‌های محاسباتی فوق با مقادیر بحرانی ارائه شده توسط Franses و Hobijn (۱۹۹۷) در سطح پنج درصد مقایسه شده، کوچکتر بودن مقادیر آماره‌های محاسباتی از مقادیر بحرانی بیانگر وجود ریشه واحد در آن فراوانی است. به منظور تعیین همزمان وجود ریشه واحد در تمامی فراوانی‌های غیرفصلی و فصلی و تمامی فراوانی‌های فصلی به ترتیب از آماره‌های Taylor، $F_{1,2,\dots,12}$ و $F_{2,\dots,12}$ استفاده خواهد شد. در این دو آزمون، فرضیه صفر مبنی بر وجود ریشه واحد در تمامی فراوانی‌ها در مقابل فرضیه عدم وجود حداقل یک ریشه واحد مورد بررسی قرار خواهد گرفت (Pich و Arnade، ۱۹۹۸). هنگامی که سری زمانی ایستا باشد، تعیین درجه خودتوضیحی غیرفصلی (AR)، درجه میانگین متحرک غیرفصلی (MA)، درجه خودتوضیحی فصلی (SAR) و درجه میانگین متحرک فصلی (SMA) میسر خواهد شد. تعداد خیزهای^۱ معنی‌دار آماری توابع خودهمبستگی^۲ (ACF) و خودهمبستگی جزئی^۳ (PACF) درجات الگو را تعیین می‌نماید (Stoffer و Shumway، ۲۰۰۶). ضروری است تا الگوی SARIMA اولیه را با استفاده از

1- Spikes
2- AutoCorrelation Function
3- Partial AutoCorrelation Function

درجات پیشنهادی فوق تشکیل داد اما در نهایت الگوی برتر با توجه به مقادیر شاخص‌های اطلاعات^۱ مانند AIC و SC، الگوهای SARIMA با درجات مختلف حاصل از اعمال تغییر در الگوی اولیه انتخاب خواهد شد. پس از تشخیص الگوی SARIMA، در مرحله بعد، برازش الگو با استفاده از رهیافت برآورد حداکثر راستنمایی^۲ (MLE) مدنظر قرار گرفت. برقراری شرایط نوفه سفید برای اجزاء اخلاص، شرط حیاتی در مرحله برازش الگو است. در گام سوم، تشخیص نیکوئی برازش مدنظر بوده، فرض اساسی الگوهای ARIMA این است که اجزاء اخلاص تصادفی، یک سری مستقل و دارای توزیع همسان با میانگین و واریانس محدود باشد (Eric، ۲۰۱۰). اگر ε_t دارای توزیع نرمال با میانگین صفر و واریانس σ^2 باشد، سری را نوفه سفید Gaussian می‌نامند (Pich و Arnade، ۱۹۹۸). در سری‌های نوفه سفید مقادیر خودهمبستگی به لحاظ آماری برابر با صفر خواهد بود. در مرحله تشخیص نیکوئی برازش بررسی وجود خودهمبستگی، ناهمسانی واریانس و نرمال بودن اجزاء اخلاص مدنظر بوده، که در این راستا به ترتیب استفاده از آزمون‌های Q (Box-Pierce) یا آماره Q^* (Ljung-Box)، آزمون ARCH-LM و Shapiro توصیه می‌شود (Enders، ۱۹۹۵). گام چهارم در استفاده از الگوی SARIMA پیش‌بینی است. اگر الگوی مناسب توضیح‌دهنده فرآیند تولید داده^۳ (DGP) شناسایی شد، می‌توان آن را به منظور پیش‌بینی مقادیر آتی مورد استفاده قرار داد. به منظور انتخاب الگوی برتر به لحاظ صحت پیش‌بینی استفاده از آماره‌های دقت پیش‌بینی مانند خطای میانگین^۴ (ME)، ریشه دوم میانگین خطا^۵ (RMSE)، میانگین خطای مطلق^۶ (MAE)، میانگین درصد خطا^۷ (MPE) و میانگین درصد خطای مطلق^۸ (MAPE) مدنظر قرار خواهد گرفت. الگوی برخوردار از مقادیر کمینه شاخص‌های فوق به عنوان برترین الگو انتخاب می‌شود.


1- Information Criterion
 2- Maximum Likelihood Estimation
 3- Data Generation Process
 4- Mean error
 5- Root Mean Square Error
 6- Mean Absolute Error
 7- Mean Percentage Error
 8- Mean Absolute Percentage Error

۲-۳ شبکه‌های عصبی مصنوعی

شبکه عصبی مصنوعی الگو برداری از سیستم عصبی بیولوژیکی می‌باشد. هر عصب از سه قسمت اساسی تشکیل شده است: دندریتها، بدنه سلول و اکسون که دندریتها شبیه درخت هستند که ورودیهای شبکه عصبی را به سمت بدنه سلول هدایت می‌کنند. بدنه سلول سیگنالهای ورودی را جمع می‌کند. اکسون یک رشته بلند است که سیگنال را از بدنه سلول به خارج و به عصب دیگر حمل می‌کند. محل اتصال یک اکسون از یک سلول به دندریت سلول دیگر سیناپس نامیده می‌شود.

۱-۲-۳ نرون تک ورودی

یک نرون تک ورودی در شکل ۱ نشان داده شده است. ورودی اسکالر در یک عدد به نام وزن w ضرب می‌شود و در فرم wp به جمع کننده ارسال می‌شود. ورودی دیگر مقدار یک است که در مقدار بایاس b ضرب می‌شود و سپس به جمع کننده فرستاده می‌شود. مجموع خروجی n است که به عنوان ورودی net خوانده می‌شود و به تابع انتقال f داده می‌شود که آن نیز خروجی اسکالر نرون یعنی a را تولید می‌کند.



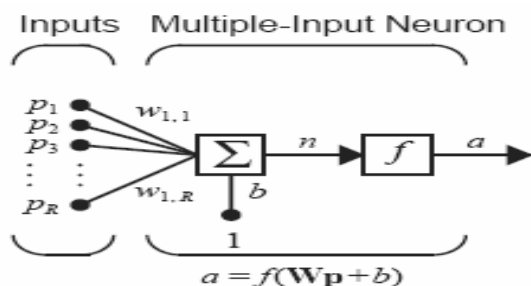
شکل ۱- نرون تک ورودی

۲-۲-۳ نرون با چند ورودی^۲

غالبا، نرون بیش از یک ورودی دارد. یک نرون با R ورودی در شکل ۲ نشان داده

1- Transfer Function
2- Multiple – input neuron

شده است. ورودی‌های خاص p_1, p_2, \dots, p_R هر کدام دارای وزن خاص خود به ترتیب W $1,1, W_{1,2}, \dots, W_{1,R}$ هستند که بصورت بردار وزن W نشان داده می‌شود:



شکل ۲- نرون چند ورودی

بایاس b ، با حاصل ضرب ورودی‌ها در وزن‌ها جمع می‌شود. و ورودی net را تولید می‌کند که برابر است با:

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (10)$$

خروجی نرون به صورت زیر نوشته می‌شود:

$$a = f(wp + b)$$

۳-۲-۳ شبکه عصبی BP^۱

الگوریتم BP برای آموزش شبکه چند لایه بکار می‌رود که معیار عملکرد آن متوسط مربع خطا^۲ می‌باشد. برای یک شبکه‌ی خطی یک لایه، خطا تابعی خطی از وزن‌های شبکه و مشتق‌های آنهاست. در شبکه‌ی چند لایه با تابع غیر خطی، رابطه بین وزن‌های شبکه و خطا بسیار پیچیده است. قانون آموزش پرسپترون و الگوریتم^۳ LMS که برای آموزش پرسپترون ایجاد شده اند تنها برای حل مسائلی که بصورت خطی بتوان آنها را طبقه بندی نمود، می‌توانند استفاده شوند. برای حل مسئله از شبکه چند لایه پرسپترون که توسط الگوریتم BP آموزش داده می‌شود، استفاده می‌شود که هم اکنون از شبکه‌هائی

1- Back Propagation(BP)
2- Mean Square Error
3- Least Mean Square


است که بیشترین کاربرد را دارد.

۳-۲-۳-۱ پرسپترون چند لایه

در شکل ۳ پرسپترون سه لایه نشان داده شده است. (برای سادگی، سه لایه پشت سر هم نشان داده شده است). هر لایه دارای تعداد متفاوت نرون و نیز تابع انتقال متفاوت می‌باشد.

برای نشان دادن شماره لایه از عدد استفاده می‌شود برای مثال ماتریس وزن برای لایه اول به صورت W^1 نوشته می‌شود.

برای تعریف ساختمان شبکه چند لایه، استاندارد زیر را بکار می‌بریم که تعداد ورودیها، سپس تعداد نرونها در هر لایه قرار می‌گیرد. $R-S^1-S^2-S^3$ بطوریکه R تعداد ورودی، S^1 تعداد نرون لایه، S^2 تعداد نرون لایه ۲ و S^3 تعداد نرون لایه ۳ می‌باشد.



شکل ۳- پرسپترون چند لایه

۲-۳-۲-۲ الگوریتم BP

برای شبکه‌های چند لایه، خروجی یک لایه، ورودی لایه دیگر است معادله‌ای که این عملکرد را توضیح می‌دهد عبارتست از:

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \quad m = 0, 1, \dots, M-1 \quad (11)$$

بطوریکه m شماره لایه در شبکه است. نرونهای لایه اول، ورودیهای خارجی را دریافت می‌کنند یعنی: $a^0 = p$ ، خروجیهای نرونها در لایه آخر بصورت $a = a^M$ می‌باشد.

الگوریتم BP برای شبکه چند لایه، گونه‌ای از الگوریتم LMS می‌باشد و هر دو

الگوریتم یک نوع عملکرد یعنی MSE را بکار می‌برند: عملکرد الگوریتم BP به این صورت است که:

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \quad (12)$$

بطوریکه P_q یک ورودی و یک خروجی مطلوب می‌باشد. هر ورودی که به شبکه اعمال می‌شود خروجی شبکه با مقدار مطلوب^۱ مقایسه می‌شود. الگوریتم باید پارامترهای شبکه را برای مینیمم کردن خطای مربع متوسط (MSE) تنظیم نماید یعنی:

$$F(x) = E[e^2] = E[(t - a)^2] \quad (13)$$

بطوریکه x بردار وزن و بایاس شبکه می‌باشد. اگر شبکه دارای چند خروجی باشد، داریم:

$$F(x) = E[e^T e] = E[(t - a)^T (t - a)] \quad (14)$$

با الگوریتم LMS خطای MSE توسط رابطه زیر تقریب زده می‌شود:

$$\hat{F}(x) = (t(k) - a(k))^T - a(k) = e^T(k)e(k)$$

به طوری که انتظارات خطای مربع با توان دوم خطا در تکرار k جایگزین شده است.

الگوریتم تندترین شیب^۲ برای تقریب خطای متوسط مربعات برابر است با:

$$W_{i,j}^m(k+1) = W_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial W_{i,j}^m} \quad (15)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (16)$$

بطوریکه α نرخ آموزش می‌باشد. بدلیل اینکه خطا بصورت غیر مستقیم تابعی از وزنها در لایه مخفی می‌باشد در نتیجه مشتق‌ها براحتی محاسبه نمی‌شوند و مطابق قانون زنجیر را برای محاسبه مشتق‌ها بکار خواهیم برد.

با توجه به رویکرد ارائه شده، در ادامه به منظور تبیین الگوی مناسب جهت بررسی رفتار و پیش‌بینی مقادیر آتی سری زمانی ماهیانه صادرات غیرنفتی ایران، نخست ماهیت


1- Target
2- Steepest Descent

رفتار ماهیانه سری زمانی با استفاده از رهیافت آزمون ریشه واحد FH تعیین شد. پس از تعیین وجود ریشه‌های غیر فصلی و فصلی در فراوانی‌های مربوطه، در گام بعد، با بهره‌گیری از فیلتر مناسب الگوی SARIMA برازش شده و در نهایت پس از انجام مراحل تشخیص و گزینش الگوهای پایدار، الگوی برتر به منظور پیش‌بینی انتخاب خواهد شد و سپس از الگوهای شبکه عصبی برای پیش‌بینی استفاده شده و در نهایت نتایج حاصل از پیش‌بینی دو روش مذکور با یکدیگر مقایسه خواهد شد.

۴- برآورد مدل و تجزیه و تحلیل آن

بررسی نمودار انباشتگی فصلی سری زمانی ماهیانه صادرات غیر نفتی ایران نشان داد که به طور متوسط، طی سال‌های ۱۳۸۰ تا ۱۳۸۸ بیشترین حجم صادرات در ماه آذر و کمترین میزان آن در ماه فروردین رخ داده است. در دوره مورد بررسی، میزان بیشینه صادرات در ماه آذر سال ۱۳۸۸ و مقدار کمینه آن نیز در فروردین ماه سال ۱۳۸۰ می‌باشد. طی این دوره بیشترین نوسانات صادرات غیر نفتی بین ماه‌های مختلف یک سال، متعلق به سال ۱۳۸۸ (با انحراف معیار ۳۳۷۰۷۴۷) است. به طور متوسط اختلاف بین مقدار بیشینه و کمینه صادرات غیر نفتی ماه‌های مختلف برای سال‌های ۱۳۸۰ تا ۱۳۸۸ معادل با ۲۰۷۱۵۴۷۸ میلیون ریال بوده، بیشترین مقدار اختلاف یادشده (۱۰۵۵۰۵۰۸ میلیون ریال) در سال ۱۳۸۸ و کمترین اختلاف (۳۵۰۵۹۲ میلیون ریال) نیز در سال ۱۳۸۰ به ثبت رسیده است.

نمودار ۱- انباشتگی فصلی صادرات غیر نفتی ایران طی سال‌های ۱۳۸۰ تا ۱۳۸۸.



اسفند بهمن دی آذر آبان مهر شهریور مرداد تیر خرداد اردیبهشت فروردین
ماخذ: یافته‌های پژوهش.

به منظور تبیین الگوهای رفتاری داده‌های ماهیانه صادرات غیر نفتی ایران در گام

نخست با استفاده از آزمون FH و Taylor وجود ریشه واحد در فراوانی‌های غیرفصلی و فصلی بررسی شد. به منظور انتخاب وقفه‌های مناسب متغیر وابسته در آزمون FH از آماره LM استفاده شد، در این راستا پذیرش وقفه بهینه با مدنظر قرار دادن عدم وجود خود همبستگی و ناهمسانی واریانس شرطی صورت گرفت. با انتخاب طول وقفه اولیه ۳۶ ماه، وقفه بهینه مورد استفاده در آزمون FH وقفه اول متغیر وابسته است. با انتخاب وقفه‌های فوق مقادیر آماره‌های LM(1) و LM(12) به ترتیب برابر با ۰/۰۳۶ و ۰/۰۰۱ بوده که دال بر عدم وجود خودهمبستگی در الگو می‌باشد. از سوی دیگر، مقادیر آماره-های ARCH(1) و ARCH(12) نیز به ترتیب برابر با ۱/۰۱ و ۰/۷۵ بوده که گویای عدم وجود ناهمسانی واریانس شرطی از درجه ۱ و ۱۲ است.

جدول ۱- نتایج حاصل از آزمون ریشه واحد FH.

نوع آزمون	فراوانی فصلی	مقدار محاسباتی (الگوی دارای عرض از مبدأ و روند)	مقدار بحرانی (در سطح احتمالاتی پنج درصد)
آزمون $t: \pi_1 = 0$	۰	-۶/۱۷	-۳/۴۴
آزمون $t: \pi_2 = 0$	π	-۲/۴۲	-۲/۶۵
آزمون $F: \pi_3 = \pi_4 = 0$	$\pi / 2$	۳/۷۳	۵/۷۷
آزمون $F: \pi_5 = \pi_6 = 0$	$2\pi / 3$	۵/۸۳	۵/۷۷
آزمون $F: \pi_7 = \pi_8 = 0$	$\pi / 3$	۱۰/۴۶	۵/۷۷
آزمون F	$5\pi / 6$	۷/۰۲	۵/۸۴
آزمون F	$\pi / 6$	۳/۷۷	۵/۸۴

ماخذ: یافته‌های پژوهش.

بر اساس نتایج جدول (۲)، کوچکتر بودن قدرمطلق مقادیر محاسباتی از مقادیر مطلق بحرانی در سطح احتمالاتی پنج درصد برای فراوانی‌های π ، $\pi / 2$ و $\pi / 6$ گویای وجود ریشه‌های واحد فصلی در چرخه‌های ۶، ۳ و ۱ بوده، از این رو، ترکیب سه فیلتر $(1+L)$ ، $(1+L^2)$ و $(1-\sqrt{3}L+L^2)(1+\sqrt{3}L+L^2)$ باید مورد استفاده قرار گیرد. نتایج حاصل از به کارگیری آزمون Taylor نیز بر نتایج حاصل از الگوی FH تأکید دارد.

جدول ۲- نتایج حاصل از آزمون ریشه واحد Taylor.

مقدار بحرانی	مقدار محاسباتی	فراوانی فصلی	نوع آزمون
۵/۸۲	۱۰/۳۹	$0, \pi, \frac{\pi}{2}, \frac{2\pi}{3}, \frac{\pi}{3}, \frac{5\pi}{6}, \frac{\pi}{6}$	آزمون F: $\pi_1 = \dots = \pi_{12} = 0$
۴/۵	۷/۱۵	$\pi, \frac{\pi}{2}, \frac{2\pi}{3}, \frac{\pi}{3}, \frac{5\pi}{6}, \frac{\pi}{6}$	آزمون F: $\pi_2 = \dots = \pi_{12} = 0$

ماخذ: یافته‌های پژوهش.

بزرگتر بودن مقدار مطلق آماره محاسباتی $F_{1,2,\dots,12}$ از مقدار بحرانی بیانگر عدم وجود تمامی ریشه‌های غیرفصلی و فصلی بوده، همچنین مقدار آماره $F_{2,\dots,12}$ نیز گویای عدم وجود تمامی ریشه‌های فصلی است. پس از تعیین نوع فیلتر مورد استفاده و ایستا نمودن سری زمانی ماهیانه صادرات غیرنفتی، توابع ACF و PACF تشکیل شد و درجات الگوی اولیه SARMA برگزیده شد. بر این اساس، مقادیر $p=4, q=6, P=0$ و $Q=1$ برای الگوی اولیه مدنظر قرار گرفت. علاوه بر الگوی اولیه، درجات مختلف دیگری نیز برای برازش الگوهای SARMA لحاظ شد. ضرایب رگرسیون و آماره‌های نیکویی برازش سه الگوی برتر SARMA که فاقد مشکل خودهمبستگی و ناهمسانی واریانس بوده، در جدول زیر ارائه شده است.

جدول ۳- آماره‌ها و نتایج مربوط به الگوهای SARMA برتر.

آماره	SARMA (۶,۴) (۱,۰)	SARMA (۶,۴) (۱,۱)	SARMA (۷,۴) (۱,۱)
Q(beg.)	-	۰/۰۸۸ {۲/۹}	۰/۱۰۲ {۲/۶۷}
Q(۲۴)	۲/۵۲ {۰/۱۱۲}	-	-
Q(۲۴)	۱۶/۱۶ {۰/۲۴۱}	۰/۵۷۴ {۱/۴۷}	۰/۵۵۴ {۹/۷۴}
AIC	-۳/۷۸	-۳/۸۹	-۳/۸۶
SC	-۳/۴۸	-۳/۵۶	-۳/۵۱
AR(۱)	-	۰/۴۹۷۴۰ (۴/۳۴۸)	۰/۴۸۵۹۷ (۴/۰۹۳)
AR(۲)	-	-۰/۳۱۴۷۲ (-۲/۳۷۶)	-۰/۳۱۲۹۹ (-۲/۳۸۲)
AR(۳)	۰/۴۴۹۴۹ (۳/۷۷۹)	۰/۴۵۵۷۱ (۳/۵۷۷)	۰/۴۲۲۰۶ (۳/۱۰۵)
AR(۴)	-۰/۳۳۸۶۹ (-۲/۹۲۷)	-۰/۱۸۹۹۵ (-۱/۵۰۳)	-۰/۱۷۶۲۹ (-۱/۲۸۵)
AR(۵)	۰/۱۹۵۴۱ (۱/۶۷۳)	۰/۱۲۵۳۵ (۱/۰۱۶)	۰/۱۰۲۸۹ (۰/۷۷۳۷)
AR(۶)	-۰/۱۰۷۳۹ (-۱/۰۳۷)	-۰/۱۲۵۶۱ (-۱/۶۶)	-۰/۰۸۵۲۳ (-۰/۶۶۱۲)
AR(۷)	-	-	-۰/۰۲۱۸۶ (-۰/۱۹۰۴)

آماره	SARMA (۶,۴) (۱,۰)	SARMA (۶,۴) (۱,۱)	SARMA (۷,۴) (۱,۱)
MA(۱)	-۰/۵۷۴۰۵(-۱۶/۴۲)	-۰/۵۹۰۰۵(-۱۱/۶۰)	-۰/۶۱۰۸۱(۱۰/۱۶)
MA(۲)	۰/۰۳۴۷۹(۰/۹۲۷۶)	-۰/۰۶۳۵۹(-۱/۰۲۶)	-۰/۰۷۴۴۲(-۱/۰۵۴)
MA(۳)	۰/۵۶۸۷۴(۱۳/۹۶)	۰/۵۱۲۳۵(۸/۲۱۶)	۰/۴۹۸۴۳(۷/۱۱۹)
MA(۴)	۰/۹۳۶۵۲(۳۵/۱۹)	۰/۸۸۹۳۰(۱۹/۴۸)	۰/۸۹۴۸۶(۱۹/۴۵)
SAR(۱)	-	۰/۹۷۰۵۱(۴۱/۱۵)	۹۷۴۱۴۱۴(۴۳/۲۵)
SMA(۱)	۰/۳۵۵۳۳(-۳/۵۸۵)	۰/۵۷۶۵۵(۵/۶۴۸)	۰/۶۰۰۳۷(۶/۰۲۷)
α	۰/۰۱۶۰۵(۳/۳۹۵)	۰/۰۰۰۲۴(۰/۲۹۷۳)	۰/۰۰۰۲۳(۰/۲۶۴۴)

اعداد داخل {} سطح معنی‌داری و اعداد داخل () مقادیر آماره t را نشان می‌دهند.

پس از برازش و تعیین الگوهای برتر، با استفاده از آن، پیش‌بینی مقادیر صادرات غیرنفتی ایران برای ماه‌های سال ۱۳۸۹ مدنظر قرار گرفت. نتایج پیش‌بینی برای الگوی SARIMA موید برتری الگوی (۱,۱) (۷,۴) ASARM می‌باشد که براساس این الگوی برتر پیش‌بینی فروردین تا مهر ماه سال ۱۳۸۹ ارائه شد. همانطور که ملاحظه شده الگوی (۱,۱) (۷,۴) SARMA مقدار صادرات غیرنفتی فروردین ماه سال ۱۳۸۹ را با خطای ۱/۲۳ درصد پیش‌بینی نموده است. از این رو، قدرت پیش‌بینی این الگو در دوره کوتاه مدت بسیار مناسب می‌باشد.

جدول ۴- پیش‌بینی مقادیر آبی با استفاده از الگوهای SARMA برتر.

ماه	مقدار واقعی	SARMA (۶,۴) (۱,۰)	SARMA (۶,۴) (۱,۱)	SARMA (۷,۴) (۱,۱)
فروردین	۱۸۵۹۱۴۴۴	۲۳۵۳۶۰۷۹	۱۹۶۵۷۹۴۵	۱۸۸۲۰۲۸۲
اردیبهشت	۲۱۰۸۲۱۵۲	۱۹۵۰۵۱۳۸	۱۸۵۱۸۸۲۹	۱۹۱۵۴۶۵۱
خرداد	۱۹۰۰۰۰۰۵	۲۵۵۸۶۹۵۳	۲۵۳۰۴۷۵۱	۲۴۳۵۹۹۴۹
تیر	-	۱۵۸۷۴۹۹۳	۱۲۵۵۳۷۷۱	۱۳۷۹۵۱۶۷
مرداد	-	۴۱۵۶۸۷۴۷	۳۹۹۴۶۶۱۱	۳۶۲۳۱۶۰۲
شهریور	-	۲۲۱۵۹۷۴۷	۱۳۹۱۸۲۸۷	۱۵۰۱۱۵۷۰۱
مهر	-	۴۴۴۷۱۵۶۹	۵۳۶۱۲۷۰۸	۴۸۷۶۱۶۱۹

ماخذ: یافته‌های پژوهش.

به منظور مقایسه قدرت پیش‌بینی الگوهای فوق شاخص‌های دقت پیش‌بینی ME، RMSE، MAE، MPE و MAPE محاسبه شد. نتایج شاخص‌های یادشده در جدول زیر ارائه شده است.

جدول ۵- آزمون دقت پیش‌بینی الگوهای SARMA برتر برای دو ماه نخست سال ۱۳۸۹.

MAPE	MPE	MAE	RMSE	ME	نوع الگو
۱۷/۰۳	۹/۵۵	۳۲۶۰۸۲۵	۱۴۹۸۳۳۲	-۱۶۸۳۸۱۱	SARMA (۶,۴) (۱,۰)
۸/۹۴	-۳/۲۱	۱۸۱۴۹۱۲	۸۰۱۴۵۹	۷۴۸۴۱۱	SARMA (۶,۴) (۱,۱)
۵/۱۸	-۳/۹۵	۱۰۷۸۱۷۰	۵۶۰۳۲۹	۸۴۹۳۳۱	SARMA (۷,۴) (۱,۱)

ماخذ: یافته‌های پژوهش.

توجه به علائم و مقادیر دو شاخص ME و MAE از یک سو و دو شاخص MPE و MAPE از سوی دیگر بیانگر وجود مشکل برازش بیش از حد در مقادیر متوسط برای الگوی SARMA (۶,۴) (۱,۰) بوده، حال آنکه دو الگوی دیگر فاقد این مشکل می‌باشند. به منظور انتخاب الگوی نهایی برتر مقادیر شاخص MAPE برای دو الگوی SARMA (۶,۴) (۱,۱) و SARMA (۷,۴) (۱,۱) مورد مقایسه قرار گرفت. نتایج بیانگر خطای پیش‌بینی کمتر الگوی SARMA (۷,۴) (۱,۱) بوده، از این رو، این الگو با خطای متوسط ۵/۱۸ درصد به عنوان الگوی نهایی برتر انتخاب شد و قدرت پیش‌بینی این الگو در دوره کوتاه مدت بسیار مناسب می‌باشد.

جهت پیش‌بینی صادرات غیرنفتی با استفاده از شبکه عصبی مصنوعی از نرم افزار MATLAB استفاده شده است.

داده‌های آموزش سری زمانی ماهیانه ارزش صادرات غیرنفتی طی سال‌های ۱۳۸۰ تا ۱۳۸۸ در نظر گرفته شده است. برای شبکه عصبی طراحی شده برای پیش‌بینی مقادیر صادرات غیر نفتی ساختار زیر در نظر گرفته شده است: باید داده‌ها را سه قسمت کنیم که داریم:

۱- داده‌های آموزش^۱: ۷۰٪ (۱۳۸۰-۱۳۸۵)

۲- داده‌های آزمایش^۲: ۲۰٪ (۱۳۸۰-۱۳۸۵)

۳- داده‌های اعتبار بخشی^۳: ۱۰٪ (سال ۱۳۸۸)

داده‌های آموزش برای این استفاده می‌شود که شبکه آموزش ببیند. بعد از طراحی شبکه از داده‌های آزمایش برای آزمایش شبکه‌ی طراحی شده استفاده می‌شود لازم به

1- Train
2- Test
3- Check Validation

ذکر است که داده‌های آزمایش از داخل داده‌های آموزش انتخاب می‌شوند. داده‌های اعتبار بخشی داده‌هایی هستند که در آموزش شرکت نکرده‌اند و برای بررسی عملکرد صحیح شبکه استفاده می‌شوند.

قبل از تعیین تعداد نرون‌ها، تابع انتقال را برای لایه میانی تعیین می‌کنیم معمولاً از توابع لوگ سیگموئید و tansig به عنوان تابع انتقال استفاده می‌شود به طوری که برای داده‌های ورودی مثبت و خروجی مثبت تابع لوگ سیگموئید و اگر داده‌ها مقادیر منفی داشته باشند تابع tansig پیشنهاد می‌شود. معمولاً در لایه میانی از توابع انتقال خطی استفاده نمی‌کنند بدلیل اینکه کل شبکه خطی می‌شود و شبکه نمی‌تواند تابع یا سیستم را شناسایی کند. اما تابع خروجی را عمدتاً خطی قرار می‌دهند مگر اینکه داده‌ها نرمال شده باشند. در این تحقیق از تابع لوگ سیگموئید برای تابع انتقال لایه میانی و از تابع خطی برای لایه خروجی استفاده شد. برای آموزش تعداد نرون‌ها را ۱۲ تا برای لایه اول و یک نرون برای لایه آخر در نظر گرفتیم. نتایج حاصل از شبکه عصبی طراحی شده در جدول ۶ آمده است.

جدول ۶- مقایسه نتایج پیش بینی با استفاده از الگوی شبکه عصبی مصنوعی با مقادیر واقعی (سال ۱۳۸۸)

الگوی ANN		ماه
مقادیر پیش بینی شده	مقادیر واقعی	
۱۰۵۴۶۱۹۲	۱۰۴۹۷۹۰۸	فروردین
۱۵۳۵۱۱۹۰	۱۵۱۱۸۷۴۰	اردیبهشت
۱۴۰۸۱۲۶۹	۱۴۱۵۲۹۴۴	خرداد
۱۲۴۰۰۳۱۲	۱۲۳۰۳۸۴۵	تیر
۱۹۴۹۹۱۲۵	۱۹۴۸۷۵۲۳	مرداد
۱۷۸۴۵۴۹۶	۱۷۷۷۶۸۱۵	شهریور
۱۶۴۴۵۱۳۰	۱۶۴۳۲۴۹۰	مهر
۱۹۸۷۴۰۴۰	۱۹۹۳۹۸۰۰	آبان
۲۱۰۱۵۸۸۳	۲۱۰۴۸۴۱۶	آذر
۲۱۰۰۰۰۳۴	۲۱۰۰۷۴۴۱	دی
۱۸۰۶۶۲۵۸	۱۷۹۴۲۹۲۸	بهمن
۱۶۷۵۸۹۴۰	۱۶۶۲۰۸۱۲	اسفند

ماخذ: یافته‌های پژوهش.

1- Normalization

برای مقایسه قدرت پیش‌بینی الگوی شبکه‌های عصبی مصنوعی با الگوی SARIMA از معیارهای خطای میانگین، ریشه خطای میانگین، ریشه دوم میانگین خطا، میانگین خطای مطلق، میانگین درصد خطا و میانگین درصد خطای مطلق استفاده شد که نتیجه این مقایسه نشان دهنده‌ی برتری شبکه‌های عصبی مصنوعی در پیش‌بینی میزان صادرات غیرنفتی بر الگو SARIMA است.

جدول ۸- مقایسه عملکرد شبکه عصبی مصنوعی و SARIMA

RMSE	MAPE	MPE	MAE	ME	نوع الگو
۹۷۷۲۰/۶	۰/۴۴۱	-۰/۳۲۰	۶۶۵۷۲/۷	-۴۶۷۶۷	الگوی شبکه ANN
۵۶۰۳۲۹	۵/۱۸	-۳/۹۵	۱۰۷۸۱۷۰	۸۴۹۳۳۱	الگوی SARIMA

ماخذ: یافته‌های تحقیق

۴- نتایج و پیشنهادها

دوراندیشی به منظور تحقق آرمان‌های اقتصادی مدنظر در برنامه‌های توسعه‌ای و اعمال تغییرات در برنامه‌ریزی و راهبردها، اهمیت پیش‌بینی متغیرهای اقتصادی و استفاده از الگوهای پارامتریک و غیرپارامتریک در این راستا آشکار می‌نماید. پژوهش حاضر با بهره‌گیری از الگوی پیشرفته SARIMA و الگوی شبکه عصبی مصنوعی به پیش‌بینی کوتاه‌مدت صادرات غیرنفتی ایران پرداخته است. در این راستا، پس از استفاده از آزمون ریشه واحد فصلی FH و Taylor و تعیین ریشه‌های واحد در فراوانی‌های غیرفصلی و فصلی، فیلتر مناسب به منظور ایستانمودن داده‌های سری زمانی ماهیانه صادرات غیرنفتی ایران تعیین شد. با توجه به معیارهای آماری مدنظر سه الگوی $SARMA(1,0)(6,4)$ ، $SARMA(1,1)(6,4)$ و $SARMA(1,1)(7,4)$ برآزش شد و مقادیر صادرات غیرنفتی ایران برای فروردین تا مهر ماه سال ۱۳۸۹ با استفاده از الگوی SARMA و برای تمامی ماه‌های سال ۱۳۸۹ توسط شبکه عصبی مصنوعی پیش‌بینی شد. مقایسه مقادیر شاخص‌های دقت پیش‌بینی گویای برتری قدرت پیش‌بینی الگوی شبکه عصبی مصنوعی است. از این رو، به کارگیری آن در راستای پیش‌بینی کوتاه مدت سری زمانی صادرات غیرنفتی ایران توصیه می‌شود. بدیهی است مدیران و

تصمیم‌گیرندگان اقتصادی و بازرگانی باید با بهره‌گیری از چنین یافته‌های علمی و تعامل بیشتر با متخصصان دانشگاهی بستر مدیریت بهینه و کارا در حوزه اقتصادی را فراهم آورند. انجام برنامه‌ریزی مطلوب، اتخاذ سیاست‌های کارا و تدوین راهبردهای مناسب در راستای توسعه صادرات غیرنفتی جزء از طریق ترکیب تجارب میدانی مدیران با ظرفیت‌های علمی متخصصان داخلی میسر نخواهد شد.

منابع

- آذر، عادل و افسر، امیر (۱۳۸۵). مدل سازی پیش بینی قیمت سهام با رویکرد شبکه‌های عصبی. فصلنامه پژوهش‌های بازرگانی. سال دهم، ۴۰: ۵۲-۳۳.
- ابریشمی، حمیدوگر جی، ابراهیم. احراری، مهدی و نجفیان، فرزانه (۱۳۸۸). اثرات جهانی شدن بر صادرات غیر نفتی ایران، فصلنامه پژوهشنامه بازرگانی، سال سیزدهم، شماره ۵۱: ۲۴-۱.
- شریفان، حسین و قهرمان، بیژن (۱۳۸۶). ارزیابی پیش بینی باران با بکارگیری تکنیک SARIMA در استان گلستان، مجله علوم کشاورزی و منابع طبیعی، سال چهاردهم، شماره ۳: ۲۰۹-۱۹۶.
- سینایی، حسن علی و مرتضوی، سعیدالله و تیموری اصل، یاسر (۱۳۸۴). پیش بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی. بررسی‌های حسابداری و حسابرسی. سال دوازدهم، ۴۱: ۸۳-۵۹.
- فرج زاده، زکریا و شاه ولی، ارکید (۱۳۸۸). پیش بینی قیمت محصولات کشاورزی: مطالعه موردی پنبه و برنج و زعفران، فصلنامه اقتصاد کشاورزی و توسعه، سال هفدهم، شماره ۶۷: ۴۳-۷۱.
- فلاحی، محمد علی. خالوزاده، حمید و حمیدی علمداری، سعیده (۱۳۸۴). الگوسازی غیر خطی و پیش بینی درآمدهای مالیات بر مشاغل در اقتصاد ایران (کاربرد شبکه‌های عصبی مصنوعی و مقایسه‌ی آن با الگوهای رگرسیون خطی و سری زمانی). مجله تحقیقات اقتصادی. سال ششم، ۷۶: ۱۶۷-۱۴۳.
- قدیمی، محمد رضا و مشیری، سعید (۱۳۸۱). مدل‌سازی و پیش بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی. فصلنامه پژوهش‌های اقتصادی ایران. سال چهارم، ۱۲: ۹۷-۱۲۶.
- قهرمان زاده، محمد و سلامی، حبیب الله (۱۳۸۷). الگوی پیش بینی قیمت گوشت مرغ در ایران: مطالعه موردی استان تهران، فصلنامه علوم کشاورزی ایران (ویژه اقتصاد و توسعه کشاورزی)، سال نهم، ۱: ۱۷-۱.
- مشیری، سعید (۱۳۸۰). پیش بینی تورم ایران با استفاده از مدل‌های ساختاری، سری‌های زمانی و شبکه‌های عصبی. مجله تحقیقات اقتصادی. سال پانزدهم، ۵۸: ۱۸۴-۱۴۷.
- مهدوی عادل، محمد حسین. مطهری، محب الله و نوروزی، روح الله (۱۳۸۸). نقش سرمایه گذاری

مستقیم خارجی بر صادرات غیر نفتی در اقتصاد ایران. مجله دانش و توسعه، سال شانزدهم، ۲۷: ۱۶۱-۱۸۱.

— مهربانی بشرآبادی، حسین و کوچک زاده، سمیه (۱۳۸۸). مدل‌سازی و پیش‌بینی صادرات محصولات کشاورزی ایران: کاربرد شبکه‌های عصبی مصنوعی. مجله اقتصاد و توسعه کشاورزی (علوم و صنایع کشاورزی)، سال ششم، ۱: ۴۹-۵۸.

- Ahmad, H.A., & Dozier, G.V., & Roland, D.A. (2001). Egg price forecasting using neural networks. (2001) poultry science association, Inc. 2001 J. Appl. Pout. Res. 10:162-171.
- Arnade, C., & D. Pich. (1998). Seasonality and unit roots: the demand for fruits, *Agricultural Economics*, 18: 53-62.
- Beaulieu, J.J., & Miron, J.A. (1993). seasonal unit roots in aggregate US data, *Journal of Econometrics*, 55: 305-328.
- Canova, F., & B.E. Hansen. (1995). are seasonal patterns constant over time? a test for seasonal stability. *Journal of Business and Economic Statistics*, 13:237-252.
- Dalhuisen, J.M., & Florax, R.J.G.M., & de Groot, H.L.F., & P. Nijkamp, (2003). Price and Income Elasticities of Residential Water Demand: A Meta-Analysis. *Land Economics*, 79(2): 292-308.
- Enders, W. (1995). *applied econometric time series*. John Wiley & Sons, INC. New York.
- Eric, A. (2010). Modeling and forecasting inflation rates in ghana: an application of sarima models, dissertation submitted to the School of Technology and Business Studies, Hogskolan Dalarna in partial fulfillment of the requirement for the award of Master of Science Degree in Applied Statistics.
- Franses P.H. (1991): Seasonality, non-seasonality and the forecasting of monthly time series, *International Journal of Forecasting*, 17: 199-208.
- Franses, P.H., & Hobijn, B. (1997). critical value for unit root tests in seasonal time series, *Journal of Applied Statistics*, 24: 25-47.
- Hamilton, J.D. (1994). *Time series analysis*. Princeton unit. Press, Princeton New Jersey.
- Hylleberg, S., & Engle, R., & Granger, C.W.J., & B.S. Yoo, (1990). Seasonal integration and co integration, *Journal of Econometrics*, 44: 215-238.
- Kirchgässner, G., & J. Wolters. (2007). *Introduction to modern time series analysis*. Springer-Verlag Berlin Heidelberg.
- Kleiber, C., & Zeileis, A. (2008). *Applied econometrics with r*. Springer Science Business Media, LLC, NY, USA.
- Pfaff, B. (2008). *Analysis of integrated and cointegrated time series with r*. 2ed, Springer Science Business Media, LLC, NY, USA.
- Shumway, R.H., & D.S. Stoffer. (2006). *Time Series Analysis and Its Applications with R Examples*, 2ed, Springer Science Business Media, LLC, NY, USA.
- Taylor, A.M.R. (1997). On the practical problems of computing seasonal unit root tests. *International Journal of Forecasting*, 13: 307-318.

- Tseng, F.M., & Yu, H.C. & G.H., Tzeng. (2002). Combining neural network model with seasonal time series ARIMA model, *Technological Forecasting & Social Change*, 69: 71-87.
- Wang, I., & Gouging, Qi. , & Fu, Q., & Liu, Y.(2006). soybean yield forecast application based on Hopfield and ann. model. *The Journal of American Science*. 2(3): 85-89.

Archive of SID