

رهیافت الگوسازی تلفیقی برای پیش‌بینی قیمت محصولات کشاورزی

رضا مقدسی^{*۱} - میترا ژاله رجبی^۲

تاریخ دریافت: ۱۳۹۰/۱/۲۹

تاریخ پذیرش: ۱۳۹۰/۹/۱۹

چکیده

یکی از پرکاربردترین الگوهای پیش‌بینی سری زمانی طی سه دهه اخیر، الگوی خود توضیح جمعی میانگین متحرک (ARIMA) می‌باشد. مطالعات اخیر در زمینه پیش‌بینی با شبکه عصبی مصنوعی مؤید برتری این روش بر الگوهای خطی سنتی است. این در حالی است که هیچ‌یک از این روش‌ها از کفایت لازم در پیش‌بینی سری‌های زمانی برخوردار نمی‌باشند. زیرا الگوی ARIMA توانایی شناخت روابط غیرخطی را نداشته و ANN به تنهایی قادر به شناسایی و بررسی هم‌زمان هر دو الگوی خطی و غیرخطی نمی‌باشد. از این رو با ترکیب الگوهای ARIMA و ANN و طراحی الگوی تلفیقی روابط موجود در داده‌ها با دقت بیشتری الگوسازی می‌شود. در مطالعه حاضر، الگوی تلفیقی ARIMA و ANN طراحی و دقت پیش‌بینی آن با الگوهای رقیب مقایسه شده‌است. دقت پیش‌بینی الگوها با استفاده از معیارهای معمول نظیر MSE، RMSE و MAE و همچنین معنی‌داری اختلاف میان معیارهای فوق با استفاده از آماره گرنجر و نیوبولد بررسی و آزمون شد. نتایج پیش‌بینی‌های قیمت گندم حاکی از آن است که الگوی تلفیقی به‌طور معنی‌داری دقت پیش‌بینی به‌دست آمده از الگوهای انفرادی را افزایش می‌دهد.

واژه‌های کلیدی: الگوی خود توضیح جمعی میانگین متحرک، الگوی تلفیقی، پیش‌بینی سری زمانی، شبکه عصبی مصنوعی

مقدمه

غیرخطی قابل شناسایی نمی‌باشند (۳۴). اخیراً الگوهای شبکه عصبی مصنوعی^۳ به‌طور گسترده در پیش‌بینی‌های سری زمانی، مورد مطالعه و استفاده قرار گرفته‌اند. مهم‌ترین ویژگی آن توانایی الگوسازی روابط غیرخطی و پیچیده بدون نیاز به فرضیات قبلی از ماهیت ارتباط بین داده‌ها می‌باشد (۲۲). در دنیای واقعی، سری‌های زمانی به‌ندرت خطی کامل یا غیرخطی کامل بوده و در اغلب موارد شامل هر دو فرم می‌باشند. در این صورت، الگوهای آریمای و شبکه عصبی مصنوعی هیچ یک قادر به شناسایی و الگوسازی مناسب داده‌ها نخواهند بود. زیرا الگوی آریمای توانایی الگوسازی روابط غیرخطی را نداشته و شبکه عصبی به تنهایی قادر به شناسایی و بررسی هر دو الگوی خطی و غیرخطی نمی‌باشد (۳۴). سلمن (۱۴) و ماکریداکیس و همکاران (۲۸) در مطالعات خود نشان دادند که با ترکیب چند الگوی مختلف پیش‌بینی، بدون نیاز به انتخاب الگوی بهتر و صحیح‌تر، دقت پیش‌بینی در مقایسه با الگوهای انفرادی بهبود می‌یابد. لیوکساج و همکاران (۲۷) به‌منظور پیش‌بینی مقادیر فروش، یک روش تلفیقی شبکه عصبی مصنوعی و اقتصادسنجی و گینزبورگ و هورن (۱۹) تلفیق چند شبکه عصبی پیش‌خور^۷ را ارائه داده‌اند که نتایج مؤید

به‌طور کلی یکی از مهم‌ترین اهداف طراحی الگوهای اقتصادی امر پیش‌بینی است. تلاش‌های زیادی برای توسعه و ارتقاء الگوهای پیش‌بینی صورت گرفته‌است. یکی از پرکاربردترین الگوهای پیش‌بینی سری زمانی، الگوی خود توضیح جمعی میانگین متحرک^۳ (ARIMA) می‌باشد که به‌دلیل ویژگی‌های آماری و روش معروف باکس جنکینز^۴ در طراحی مورد توجه خاص بوده‌است. علی‌رغم انعطاف‌پذیری الگوهای آریمای^۵، محدودیتی بر الگو متصور است و آن پیش فرض خطی بودن این الگوها است. در الگوهای آریمای به‌دلیل فرض ساختار همبستگی خطی شده در مقادیر سری زمانی، فرم‌های

۱ و ۲- به ترتیب دانشیار و دانشجوی دکتری گروه اقتصاد کشاورزی، واحد علوم و تحقیقات تهران، دانشگاه آزاد اسلامی
(*)- نویسنده مسئول: Email: r.moghaddasi@srbiau.ac.ir

3-Autoregressive Integrated Moving Average

4- Box-Jenkins

۵- به‌منظور خودداری از تکرار کلمات اختصاری نظیر ARMA، ARIMA و

ANN در این مقاله از معادل فارسی این واژه‌ها استفاده می‌گردد.

6- Artificial Neural Network

7- PT Feedforward

الگوهای پیش‌بینی سری‌های زمانی در اقتصاد سنجی است (۹). در الگوهای سری‌زمانی تک متغیره فرض می‌شود تمام عوامل و ارتباطات مؤثر در شکل‌گیری یک متغیر در مقادیر خود آن نمود پیدا می‌کند، بنابراین از مقادیر قبلی خود متغیر می‌توان به‌عنوان مهم‌ترین منبع برای توضیح تغییرات متغیر استفاده نمود و پیش‌بینی را تنها با استفاده از اطلاعات قبلی خود متغیر انجام داد. بر طبق این دیدگاه اگر بتوان فرآیند مولد یک متغیر را به‌دست‌آورد پیش‌بینی آن متغیر نسبتاً به‌راحتی امکان‌پذیر خواهد بود (۸). فرآیند $ARIMA(p,d,q)$ را می‌توان به‌صورت رابطه (۱) نشان داد.

$$y_t = f(t) + \sum_{i=1}^p \Phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (1)$$

که در آن:

$y_t = \Delta^d x_t = (1-L)^d x_t$
و $f(t)$ روند زمانی^۲ را (در صورت وجود) در y_t برآورد می‌کند. در فرآیند $ARIMA(p,d,q)$ ، p بیانگر تعداد جملات خودتوضیح، d مرتبه تفاضل‌گیری و q تعداد جملات میانگین متحرک می‌باشند. در صورتی که d برابر با صفر گردد فرآیند آریما تبدیل به فرآیند $ARMA$ ^۳ می‌شود. معمولاً برای تخمین الگوی آریما از روش باکس-جنکینز استفاده می‌شود که دارای چهار مرحله شناسایی^۴، تخمین^۵، تشخیص دقت پردازش^۶ و پیش‌بینی^۷ می‌باشد (۲۰).

شبکه عصبی مصنوعی ANN

شبکه عصبی مصنوعی یکی از الگوهای غیرخطی است که قادر به تقریب زنی انواع مختلفی از روابط غیرخطی در داده‌ها می‌باشد. شبکه‌های عصبی مصنوعی دارای پارچوب‌های محاسباتی انعطاف‌پذیری برای الگوسازی طیف وسیعی از مسائل غیرخطی می‌باشند. مهم‌ترین مزیت این الگوها در مقایسه با سایر الگوهای غیرخطی این است که شبکه‌های عصبی تخمین زنده‌های جامع بوده و می‌توانند طیف وسیعی از توابع را با درجه دقت بالا تقریب بزنند. قدرت شبکه‌های عصبی از پردازش‌گرهای موازی اطلاعات داده‌ها نشأت می‌گیرد (۳۴). شبکه عصبی پیش‌خور با یک لایه پنهان پرکاربردترین فرم الگو شبکه عصبی برای الگوسازی و پیش‌بینی سری‌های زمانی است (۳۵). شبکه عصبی مصنوعی بدون توجه به نوع مسأله، از یک ساختار مشابه پیروی می‌نماید. یک شبکه عصبی

برتری الگوهای تلفیقی بوده است. بنابراین تلفیق الگوهای مختلف پیش‌بینی می‌تواند احتمال شناسایی روابط مختلف (خطی و غیرخطی) در داده‌ها را افزایش داده، کارایی پیش‌بینی را بهبود بخشیده و در مجموع الگوی تلفیقی در رابطه با تغییر ساختار داده‌ها سازگارتر^۱ خواهد شد (۳۴). تلفیق الگوهای پیش‌بینی از مطالعات رید (۳۲) و باتس و گرنجر (۱۳) آغاز شد و سلمن (۱۴) یک تجدید نظر جامع در این زمینه ارائه داد. ایده اصلی ترکیب الگوهای پیش‌بینی، به‌کارگیری ویژگی‌های الگوهای پایه به‌طور همزمان برای شناسایی روابط مختلف در درون داده‌ها می‌باشد.

این مطالعه در راستای ارتقاء دقت پیش‌بینی سری‌های زمانی به دنبال تلفیق الگوهای شبکه عصبی مصنوعی و آریما و مقایسه کارایی و دقت سه الگوی شبکه عصبی مصنوعی، آریما و الگوی تلفیقی می‌باشد تا با شناخت دقیق‌ترین الگو به امر پیش‌بینی داده‌های سری زمانی مبادرت ورزد. از آنجا که پیش‌بینی صحیح قیمت محصولات کشاورزی، آثار مهمی در سیاست‌گذاری و برنامه‌ریزی‌های اقتصادی این بخش دارد و به‌کارگیری روش‌های دقیق پیش‌بینی می‌تواند علاوه بر ایجاد زمینه برای توسعه روش‌های نوین پیش‌بینی، سیاست‌گذاران این بخش را در تصمیم‌گیری‌های آتی یاری رساند. این مهم به ویژه در مورد محصولات استراتژیک همانند گندم از جایگاه ارزشمندی برخوردار است. در این مطالعه پیش‌بینی قیمت‌های جهانی محصول استراتژیک گندم به صورت روزانه پیش‌بینی می‌گردد. در زمینه مطالعات انجام شده در مورد پیش‌بینی قیمت محصولات کشاورزی می‌توان به مطالعات کهزادی و همکاران (۲۶)، گیلان پور و کهزادی (۱)، مجاوریان و امجدی (۶)، قاسمی و همکاران (۴)، نجفی و همکاران (۱۱)، مقدسی و رحیمی بدر (۱۰)، فهیمی فر (۳)، فرخزاد و شاه ولی (۲) و یاعلی جهرمی و همکاران (۱۲) اشاره کرد. در کلیه این مطالعات الگوهای مختلف پیش‌بینی اقتصاد سنجی، سری زمانی و شبکه عصبی مصنوعی به‌طور مجزا و انفرادی الگوسازی و بعد از مقایسه و ارزیابی دقت پیش‌بینی، قیمت محصولات مختلف کشاورزی با دقیق‌ترین الگو پیش‌بینی شده‌است.

در ادامه به‌منظور پیش‌بینی قیمت روزانه گندم، توسط الگوی تلفیقی، بعد از پرداختن به مبانی نظری الگوهای آریما، شبکه عصبی مصنوعی و الگوی تلفیقی، نتایج برآورد و ارزیابی الگوهای مورد نظر برای پیش‌بینی قیمت ارائه و در نهایت مباحث مذکور در بخش نهایی خلاصه و نتیجه‌گیری می‌گردد.

مواد و روش‌ها

الگوی خودتوضیح جمعی میانگین متحرک ARIMA

الگوی آریما الگوی خطی - تصادفی می‌باشد که از قدیمی‌ترین

1- Robust

2- Time Trend

3- Autoregressive Moving Average Model

4- Identification

5- Estimation

6- PT Diagnostic Checking

7- Forecasting

از این‌رو الگوی شبکه عصبی مصنوعی توضیح داده شده، یک فرم تابعی غیرخطی از مشاهدات گذشته $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ به مقادیر آتی y_t را نشان می‌دهد. به طوری که:


$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, w) + \varepsilon_t \quad (4)$$

که در آن w یک بردار از همه پارامترها و f یک تابع تعیین شده توسط شبکه و وزن‌های ارتباطی می‌باشند. بنابراین شبکه عصبی مصنوعی با یک الگو خود توضیح غیرخطی معادل و برابر است.

تعداد نرون‌های ورودی، تعداد لایه‌های پنهان، تعداد نرون‌ها در هر لایه پنهان، تعداد نرون‌های خروجی و تابع فعالسازی در هر نرون، ساختار یک شبکه عصبی را تشکیل می‌دهند. همه این موارد بایستی به‌وسیله محقق و یا پیش توضیحات مسأله مورد نظر، قبل از آموزش و آزمون شبکه عصبی انتخاب شوند. مطابق با قانون تقریب زنده جامع^۸، یک شبکه عصبی مصنوعی صرفاً با یک لایه پنهان با دقت بالایی قادر به شناسایی روابط موجود در داده‌ها خواهد بود. اما سایینکو^۹ (۱۵)، فاناهاشی^{۱۰} (۱۸)، هورنیک و همکاران^{۱۱} (۲۴) در مطالعات خود نشان دادند که در برخی شرایط، شبکه عصبی با یک لایه پنهان، ممکن است به لحاظ روانی محاسباتی و تعمیم مسائل، شبکه عصبی با یک لایه پنهان، ساختار بهینه‌ای ارائه نخواهد داد و تعداد لایه‌های پنهان شبکه بایستی بیش از یک لایه تعیین گردد. همان‌گونه که گفته شد، هر نرون همه ورودی‌ها را دریافت می‌کند و آن‌ها را با وزن‌های مختلف ترکیب می‌کند و ورودی ترکیب شده از طریق یک تابع فعالسازی عبور داده می‌شود تا خروجی را که به‌عنوان ورودی برای واحد دیگر محسوب می‌شود، تولید کند.

در ادبیات شبکه عصبی، به جای تخمین ضرایب از اصطلاح یادگیری^۹ یا آموزش^{۱۰} برای پیدا کردن ارزش‌های وزن‌های شبکه استفاده می‌شود (۵). هدف از آموزش، به‌روزرسانی و تعدیل وزن‌های ارتباطی، در جهت حداقل سازی خطای شبکه است. در طول مسیر طراحی، شبکه به‌طور مداوم خروجی‌ها را بر اساس دقت برآورد قبلی، تعدیل می‌کند. این فرآیند تا زمانی ادامه می‌یابد که شبکه نتواند در جهت کاهش خطاها، تغییر بزرگ‌تری در وزن‌ها صورت دهد. وقتی آموزش به خطای حداقل پیش‌بینی رسید، شبکه وزن‌ها را ذخیره می‌کند و آموزش پایان می‌پذیرد (۳۵). الگوریتم پس‌انتشار خطا^{۱۱} رایج‌ترین الگوریتم آموزش است. اساساً، فرآیند پس‌انتشار خطا شامل دو مسیر از طریق لایه‌های مختلف شبکه است. در مسیر پیش‌خور^{۱۲}،

معمولاً از سه لایه ورودی^۱، پنهان^۲ و خروجی^۳ تشکیل شده است. نرون‌های ورودی، سیگنال‌های خارجی را که به شبکه تغذیه می‌شود، دریافت می‌کنند. این سیگنال‌ها به وسیله وزن‌هایی^۴ تعدیل می‌شوند. مطابق این تعدیلات، در هر نرون خروجی، ورودی‌های موزون جمع زده می‌شوند و سپس این مجموع از طریق یک تابع فعالسازی^۵ عبور داده می‌شوند. خروجی تابع فعالسازی، خروجی مورد نظر است (۲۲). هر ورودی می‌تواند به بیش از یک نرون خروجی وارد شود و هر خروجی ممکن است ورودی مجموعه دیگری از نرون‌های خروجی جدید شود. در این حالت، نرون‌ها در لایه میانی، نرون‌های پنهان نامیده می‌شود. توضیحات ارائه شده یک شبکه پیش‌خور^۶ را معرفی می‌نماید. وقتی یک شبکه پیش‌خور نرون‌های پنهان را شامل شود، شبکه پرسپترون چند لایه^۷ نامیده می‌شود (۲۳). شکل ۱ یک شبکه پرسپترون چند لایه با یک لایه پنهان را نمایش می‌دهد.



شکل ۱- شبکه عصبی پرسپترون چند لایه با یک لایه پنهان (۷)

روابط بین خروجی y_t و ورودی‌ها $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ از رابطه ریاضی زیر تبعیت می‌کند.

$$y_t = \alpha_0 + \sum_{j=1}^q \alpha_j g(\beta_{0j} + \sum_{i=1}^p \beta_{ij} y_{t-i}) + \varepsilon_t \quad (2)$$

که در آن α_j ($j = 1, 2, \dots, q$) و β_{ij} ($i = 1, 2, \dots, p; j = 1, 2, \dots, q$) پارامترهای الگو بوده و اغلب وزن‌های ارتباطی نامیده می‌شوند. P تعداد نرون‌های ورودی و q تعداد نرون‌های لایه پنهان است. برای تابع فعالسازی لایه پنهان اغلب تابع فعالسازی لجستیک استفاده می‌شود.

$$g = \frac{1}{1 + \exp(-x)} \quad (3)$$

- 1- TPPT Input Layer
- 2- TPPT Hidden Layer
- 3- TPPT Output Layer
- 4- TPPT Weight
- 5- TPPT Transfer Function
- 6- TPPT Feedforward
- 7- TPPT Multilayer perceptron

- 8- TPPT Universal approximater
- 9- TPPT Learning
- 10- TPPT Training
- 11- TPPT Back Propagation
- 12- TPPT Feedforward

با Π نرون ورودی، الگوی شبکه عصبی مصنوعی باقیمانده‌ها عبارت خواهد بود از:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (7)$$

که در آن f یک تابع غیرخطی تعیین شده توسط شبکه عصبی و ε_t خطای تصادفی است. با نشان دادن مقادیر پیش‌بینی از معادله (۷) به صورت \hat{N}_t ، پیش‌بینی تلفیقی عبارت خواهد بود از:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (8)$$

به‌طور خلاصه، روش پیشنهادی سیستم تلفیقی شامل دو مرحله خواهد بود. در مرحله اول، یک الگوی آریمای برای تجزیه و تحلیل بخش خطی مسئله به کار می‌رود. در مرحله دوم، شبکه عصبی برای الگوسازی باقیمانده‌های الگوی آریمای ساخته می‌شود. از آنجا که الگوی آریمای قادر به شناسایی ساختار غیرخطی داده‌ها نیست، باقیمانده‌های الگوی خطی شامل اطلاعات غیرخطی خواهد بود. الگوی تلفیقی ویژگی‌ها و توانایی‌های هر دو الگو را در تعیین و تخمین الگوهای مختلف به کار می‌گیرد.

مقایسه دقت پیش‌بینی الگوها

گاهی اتفاق می‌افتد که شبکه‌های عصبی، روابط را متفاوت از روابط داده‌ها یاد می‌گیرد و یا داده‌ها را بدون یادگیری روابط بین متغیرها یا روندهای داده‌ها، حفظ می‌کند. از این‌رو برای اطمینان از دقت و اعتبار شبکه و توانایی تعمیم شبکه و همچنین امکان مقایسه الگوهای رقیب، شبکه طراحی شده بایستی به‌طور مداوم آزمون شود. عملیات آزمون به‌وسیله عبور یک مجموعه داده مجزا تحت عنوان مجموعه آزمون^۲، از شبکه عصبی مصنوعی آموزش دیده و ثبت نتایج، نتایج، انجام می‌شود. نتایج حاصل، با نتایج واقعی مقایسه می‌گردد. شبکه آموزش دیده در صورتی پذیرفته می‌شود که نتایج خوبی برای مجموعه آزمون ارائه دهد. به‌عبارت دیگر بعد از تخمین و آموزش شبکه، برای ارزیابی، باید قدرت پیش‌بینی شبکه در خارج از نمونه^۳ را بررسی کرد. برای این منظور معمولاً داده‌ها را به دو مجموعه جدا تقسیم می‌کنند. بخش اول به مجموعه آموزش^۴ یا تخمین و مجموعه دوم به مجموعه آزمون یا اعتبارسنجی موسوم است. ابتدا ضرایب شبکه با استفاده از داده‌های مجموعه اول تخمین زده می‌شود و سپس با استفاده از داده‌های مجموعه دوم، قدرت پیش‌بینی شبکه و یا به‌عبارت دیگر، توان تعمیم آن به خارج از مجموعه داده‌های مورد استفاده در تخمین، ارزیابی می‌شود.

به‌منظور مقایسه قدرت پیش‌بینی و انتخاب بهترین روش، علاوه

داده‌ها از لایه ورودی به لایه خروجی در مسیری رو به جلو تغذیه می‌شوند. خروجی پیش‌بینی شده لایه خروجی با خروجی هدف مقایسه می‌گردند. در مسیر پس‌خور^۱، میانگین خطای محاسبه شده از طریق شبکه و از لایه خروجی به لایه ورودی به سمت عقب انتشار می‌یابد و وزن‌های اتصال، مطابق با قوانین یادگیری تعدیل می‌شوند. به‌طوری‌که پاسخ شبکه را به پاسخ دلخواه نزدیک‌تر سازد (۲۵).

الگوی تلفیقی ANN و ARIMA

الگوهای شبکه عصبی مصنوعی و آریمای برای همه شرایط و همه روابط، الگوهای جامعی نبوده و تنها در محدوده خطی و غیرخطی خاص خود موفق عمل می‌کنند. تقریب الگوهای آریمای برای مسائل غیرخطی پیچیده ناکافی بوده و از سوی دیگر کاربرد شبکه عصبی مصنوعی برای الگوسازی مسائل خطی با آشفتگی همراه می‌باشد (۳۵). برای مثال دنتون (۱۶) با استفاده از داده‌های شبیه‌سازی شده نشان داد که در صورت وجود مشاهده دور افتاده یا هم‌خطی در داده‌ها، دقت شبکه عصبی مصنوعی به‌طور معنی‌داری بهتر از الگوهای رگرسیون خطی خواهد بود. مارخام و راکس (۲۹) نیز دریافتند که کارایی شبکه عصبی برای مسائل رگرسیون خطی به اندازه نمونه و سطح آشفتگی بستگی دارد. از این‌رو به‌کارگیری کورکورانه شبکه عصبی مصنوعی برای هر نوع داده‌ای عاقلانه و منطقی به‌نظر نمی‌رسد. از آنجا که آگاهی کامل از ویژگی‌های داده‌ها در مسائل واقعی مشکل است، روش تلفیق که هم‌زمان توانایی الگوسازی الگوهای خطی و غیرخطی را دارد، می‌تواند استراتژی خوبی برای کاربردهای عملی باشد. با ترکیب الگوهای مختلف، جنبه‌های مختلفی از الگوهای پایه قابل شناسایی خواهد بود. معقول است که یک سری زمانی را ترکیبی از ۲ جز خطی و غیرخطی فرض کنیم. به‌طوری‌که:

$$y_t = L_t + N_t \quad (5)$$

L_t جز خطی و N_t جز غیرخطی را نشان می‌دهد. این دو جز بایستی از داده‌ها شناسایی و تخمین زده شوند. ابتدا اجازه می‌دهیم تا آریمای جز خطی را الگوسازی نموده، در نتیجه، باقیمانده‌ها از الگوی خطی فقط روابط غیرخطی را شامل خواهد بود. اگر e_t باقیمانده‌های الگوی خطی را نشان دهند، آنگاه:

$$e_t = y_t - \hat{L}_t \quad (6)$$

که در آن \hat{L}_t مقادیر پیش‌بینی شده از الگوی خطی را نشان می‌دهد. هر رابطه معنی‌دار غیرخطی در باقیمانده‌ها، محدودیت آریمای برآورد را نشان خواهد داد. با الگوسازی باقیمانده‌ها توسط الگوی شبکه عصبی مصنوعی، روابط غیرخطی می‌توانند شناسایی و تخمین گردند.

2- TPPT Test Set
3- TPPT Out of Sample
4- TPPT Training Set

1- TPPT Backward

و برآورد الگوی آریمای داده‌های ۲۰۰۸/۱۰/۳۰ تا ۲۰۱۰/۷/۲۱ می‌باشد.

به منظور استفاده از فرآیند آریمای پس از تعیین درجه هم‌جمع‌ی (d)، تعداد جملات خود توضیح (p) و تعداد جملات میانگین متحرک (q)، با بهره‌گیری از روش پسران و پسران (۱۹۷۷) و معیار آکائیک و شوارتز-بیزین، محاسبه شده و بر اساس کمترین آماره‌ها، فرآیندی با تعداد جملات خودتوضیح برابر با ۴ و میانگین متحرک برابر با ۴ بهترین ساختار انتخاب شده‌است. بنابراین از میان حالت‌های مختلف، فرآیند ARMA (۴,۴) به عنوان بهترین حالت برای پیش‌بینی انتخاب گردید. بعد از بررسی کفایت الگو در مرحله بعد قیمت برای مجموعه آزمون (۲۰۱۰/۷/۲۱ تا ۲۰۱۰/۱۲/۱۰) با استفاده از این الگو پیش‌بینی گردید تا با مقایسه دقت پیش‌بینی داده‌های آزمون این الگو با الگوی رقیب، الگوی دقیق‌تر جهت انجام پیش‌بینی انتخاب و مقادیر آتی قیمت گندم با استفاده از این الگو پیش‌بینی گردد. معیاره‌های خطای پیش‌بینی برای داده‌های آزمون حاصل از الگوی ARMA (۴,۴) در جدول ۲ خلاصه شده است.

مقادیر برازش شده و مقادیر واقعی سری زمانی قیمت‌های جهانی گندم برای داده‌های الگوی ARMA (۴,۴) در شکل ۲ نشان داده شده است.

الگوی شبکه عصبی مصنوعی بر پایه الگوی ARIMA

این بخش از مطالعه، با توجه به توانایی الگوهای شبکه عصبی مصنوعی و با هدف مقایسه دقت پیش‌بینی، به بررسی و برآورد شبکه عصبی مصنوعی مبتنی بر آریمای پرداخته شد. در این نوع شبکه ورودی‌های شبکه به صورت وقفه‌های متغیر مورد نظر جهت پیش‌بینی بر اساس الگوی آریمای تعیین می‌شود. بر اساس اصل تقریب‌زننده جامع، از شبکه پیش‌خور تعمیم‌یافته استفاده شده‌است. در این شبکه‌ها الگوریتم پس‌انتشار خطا به عنوان الگوریتم آموزش و همان‌گونه که گفته شد وقفه‌های برگرفته شده از الگوی آریمای به عنوان ورودی‌ها در نظر گرفته شد. به منظور دسترسی به بهترین ساختار شبکه، شبکه‌هایی با تعداد مختلف لایه‌های پنهان، توابع فعال‌سازی مختلف در لایه پنهان و قوانین مختلف یادگیری برآورد گردید. تعداد لایه‌های پنهان یک و دو، توابع فعال‌سازی لایه پنهان توابع لجستیک شامل سیگموئید و تانژانت هیپربولیک و تابع فعال‌سازی لایه خروجی تابع فعال‌سازی خطی در نظر گرفته شد.

بر معیارهای متداول از جمله، معیار میانگین مربع خطا^۱، ریشه میانگین مربع خطا^۲ و معیار میانگین قدر مطلق خطا^۳ روش ارائه شده توسط گرنجر و نیوبولد^۴ جهت آزمون معنی‌داری اختلاف خطای الگوهای رقیب نیز استفاده شده‌است. به این منظور ابتدا رابطه زیر محاسبه می‌شود:

$$r = \frac{\sum_{t=1}^{T^*} (e_t^1 + e_t^2)(e_t^1 - e_t^2)}{\sqrt{\sum_{t=1}^{T^*} (e_t^1 + e_t^2)^2 \sum_{t=1}^{T^*} (e_t^1 - e_t^2)^2}} \quad (9)$$

که در آن e_t^1 و e_t^2 به ترتیب خطای پیش‌بینی خارج از نمونه دو روش رقیب و T^* تعداد پیش‌بینی‌های خارج از نمونه است. سپس آزمون برابری دقت پیش‌بینی دو روش را می‌توان با استفاده از آماره GN^5 مورد بررسی قرار داد. این آماره دارای توزیع t با درجه آزادی $T^* - 1$ بوده و طبق رابطه ۱۰ محاسبه می‌گردد (۳۱).

$$GN = r \sqrt{\frac{T^* - 1}{1 - r^2}} \quad (10)$$

نتایج و بحث

الگوی ARIMA

در اولین قدم ایستایی سری قیمت جهانی روزانه گندم^۶ مورد بررسی قرار گرفت. برای این منظور توصیه بر این است روش‌های آزمون ایستایی با فرضیه‌های صفر مختلف به کار گرفته شود. بر این اساس ایستایی با استفاده از دو روش دیکی فولر تعمیم‌یافته و KPSS^۷ مورد بررسی قرار گرفت. در این روش‌ها فرضیه صفر آزمون‌ها متفاوت بوده به طوری که در آزمون دیکی فولر تعمیم‌یافته فرضیه صفر عدم ایستایی و در آزمون KPSS فرضیه صفر ایستایی سری زمانی است. نتایج آزمون‌ها در جدول ۱ آمده است. نتایج حاکی از آن است که متغیر مورد استفاده در الگو در سطح ایستا می‌باشد.

همان‌گونه که قبلاً ذکر شد، به منظور مقایسه روش‌های معمول پیش‌بینی، داده‌ها به دو گروه آموزش و آزمون تقسیم می‌گردد. در این بخش از مطالعه از داده‌های ۲۰۰۸/۱۰/۳۰ تا ۲۰۱۰/۷/۲۱ به عنوان آموزش و از داده‌های ۲۰۱۰/۷/۲۱ تا ۲۰۱۰/۱۲/۱۰ جهت ارزیابی و آزمون الگو استفاده شده‌است. از این رو بازه داده‌های بررسی ایستایی

- 1- TPPT Mean Square Error(MAE)
- 2- TPPT Root Mean Square Error (RMSE)
- 3- TPPT Mean Absolute Deviation (MAD)
- 4- Granger & Newbold
- 5- Granger & Newbold

۶- برگرفته از اطلاعات بورس جهانی Fibogroup.com

- 7- Kwiatkowski-Philips-Schmidt-Shin Test Statistic

جدول ۱- نتایج آزمون ایستایی سری قیمت جهانی روزانه گندم

نام متغیر	KPSS	آماره دیکی فولر	تعداد وقفه بهینه	وضعیت	وضعیت عرض از مبدأ و روند
قیمت گندم	۰/۹۹	***-۶/۲۳	۰	ایستا در سطح	با عرض از مبدأ


* و ** و *** به ترتیب نمایانگر معنی دار بودن در سطح ۱۰، ۵، ۱ درصد است

مأخذ: یافته‌های پژوهش

جدول ۲- نتایج دقت پیش‌بینی الگوی ARMA(۴,۴) برای داده‌های آزمون

نام معیار	MSE	RMSE	MAD	نوع الگو
الگوی ARMA(۴,۴)	۴۹۹.۱	۲۲.۲۴	۱۷.۵۹	

مأخذ: یافته‌های تحقیق



شکل ۲- مقادیر واقعی و برازش شده سری قیمت جهانی گندم برای داده‌های آزمون

بالتر و خطای آموزش و آزمون کمتر انتخاب گردید. بدین ترتیب از بررسی ساختارهای مختلف، شبکه عصبی مصنوعی پیش‌خور با دو لایه پنهان، ۱۵ نرون در لایه پنهان، تابع فعالسازی تانژانت هیپربولیک در لایه پنهان اول و تابع فعالسازی لجستیک در لایه پنهان دوم، با قانون یادگیری مومنتوم به‌عنوان ساختار بهینه الگوی شبکه عصبی مبتنی بر آریمای انتخاب شد. معیارهای ارزیابی دقت پیش‌بینی در جدول ۳ ارائه شده‌اند.

نمودار مقادیر برازش شده و مقادیر واقعی سری زمانی قیمت‌های جهانی گندم برای داده‌های آموزش و آزمون الگوی $(tan-sin-ANN-GF(4-2-1)lin)m$ در شکل ۳ نشان داده شده است.

الگوی تلفیقی ANN و ARIMA

به‌منظور برآورد الگوی تلفیقی شبکه عصبی مصنوعی و آریمای، ابتدا با استفاده از کل داده‌های قیمت گندم الگوی آریمای برآورد و باقیمانده‌های برآورد به‌دست آمد. بر اساس معیار کمترین آماره اکائیک و شوارتز بیزین الگوی ARMA(۴,۴) انتخاب و برآورد گردید. سپس سری باقیمانده‌های الگوی خطی دقیقاً مشابه دو الگوی قبلی به دو بخش داده‌های آموزش و آزمون تقسیم و توسط الگوی شبکه عصبی مصنوعی الگوسازی و برآورد گردید.

از میان قوانین محاسباتی الگوریتم یادگیری پس‌انتشار خطا، قوانین لونبرگ ماگوان^۱، دلتا بار دلتا^۲، مومنتوم^۳ و کنجوگیت گرادینت^۴ انتخاب گردید. چرا که این قوانین سرعت محاسبات رسیدن رسیدن به حداقل خطا را افزایش و در عین حال حجم محاسبات و حافظه مورد نیاز در محاسبات را کاهش می‌دهند. علی‌رغم وجود فرمول‌های مختلف، بهترین روش برای تعیین تعداد نرون‌های لایه پنهان روش آزمون و خطاست. به‌این منظور برای کلیه ساختارهای شبکه، تعداد نرون‌های پنهان از یک تا بیست تغییر داده شد تا این که تعداد نرون‌های لایه پنهان متناظر با بهترین معیار ارزیابی پیش‌بینی به‌دست آمده انتخاب گردید. از آنجاکه نتایج ممکن است با تکرار بیشتر و شروع آموزش شبکه با مقادیر اولیه مختلف بهبود یابد، عمل تخمین‌زدن یا به عبارت دقیق‌تر آموزش شبکه با سه شروع مجدد و ۱۰۰۰ تکرار انجام گردید. نتیجه گزارش شده برای هر ساختار بهترین نتیجه ممکن از سه بار شروع مجدد، ۱۰۰۰ تکرار و تعداد نرون بهینه برای آن ساختار است. در این شبکه‌ها، به‌منظور مقایسه الگوهای مختلف پیش‌بینی، داده‌های آموزش و آزمون مشابه هم در نظر گرفته شده‌اند. از میان ساختارهای مختلف، ساختاری با ضریب همبستگی

- 1- Levenberg-Maguan
- 2- Delta Bar Delta
- 3- Momentum
- 4- Conjugate Gradient

جدول ۳- نتایج ارزیابی و مقایسه دقت پیش‌بینی الگو شبکه عصبی مصنوعی مبتنی بر ARIMA

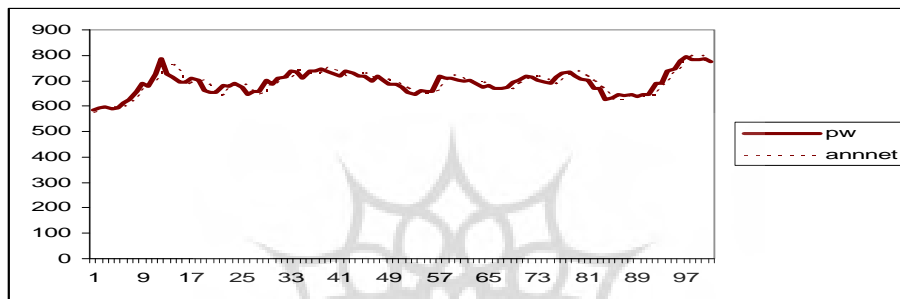
نام معیار	تعداد نرون پنهان	شروع	تکرار	MSE	RMSE	MAD	نوع الگو
	۱۵	۲	۱۶	۴۹۸.۴۴	۲۲.۲۱	۱۶.۴۹	ANN-GF(4-2-1)(tan-sin-lin)m

مأخذ: یافته‌های تحقیق

ادامه جدول ۳- نتایج ارزیابی و مقایسه دقت پیش‌بینی الگو شبکه عصبی مصنوعی باقیمانده‌های ARIMA

نام معیار	تعداد نرون پنهان	شروع	تکرار	MSE	RMSE	MAD	نوع الگو
	۱۰	۲	۱۰۰	۴۴۳.۷۵	۲۱.۰۶	۱۵.۳۷	ANN-GF(4-2-1)(tan-sin-lin)m

مأخذ: یافته‌های تحقیق



شکل ۳- مقادیر واقعی و برازش شده سری قیمت جهانی گندم برای داده‌های آزمون

باقیمانده‌ها بعد از بررسی ساختارهای مختلف، شبکه عصبی مصنوعی پیش‌خور با دو لایه پنهان، ۱۰ نرون در لایه پنهان، تابع فعالسازی تانژانت هیپربولیک در لایه پنهان اول و تابع فعالسازی لجستیک در لایه پنهان دوم، با قانون یادگیری مونتوم با کمترین خطای داده‌های آموزش و آزمون و ضریب همبستگی بالاتر به‌عنوان ساختار بهینه انتخاب شد. معیارهای ارزیابی دقت پیش‌بینی در ادامه جدول ۳ ارائه شده‌اند.

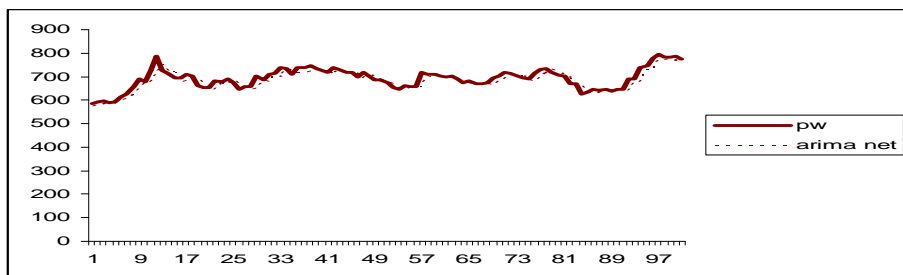
شکل‌های ۴ و ۵ نمودار مقادیر برازش شده و مقادیر واقعی سری زمانی قیمت‌های جهانی گندم برای داده‌های آزمون الگوی آریمای الگوی ANN-GF(4-2-1)(tan-sin-lin)m باقیمانده‌های آریمای را نشان می‌دهد.

در مرحله بعد پیش‌بینی‌های الگوی آریمای با پیش‌بینی‌های الگوی شبکه عصبی باقیمانده‌های الگوی آریمای جمع‌زده می‌شود تا پیش‌بینی‌های الگوی تلفیقی ARMA-ANN در جدول ۴ خلاصه شده است.

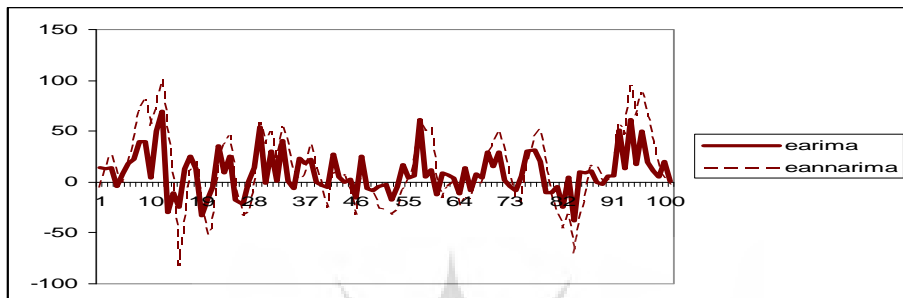
شکل ۶ مقادیر واقعی و پیش‌بینی شده قیمت جهانی گندم الگوی تلفیقی ARMA-ANN را نشان می‌دهد.

نتایج دقت پیش‌بینی سه الگو در جدول ۵ خلاصه شده است.

برای این الگو نیز از شبکه پیش‌خور تعمیم‌یافته به‌عنوان شبکه پایه و از الگوریتم پس انتشار خطا به‌عنوان الگوریتم آموزش استفاده شد. اما در طراحی این شبکه نرون‌های ورودی نیز از یک تا ۵ تغییر یافت تا بهترین تعداد نرون ورودی تعیین گردد. در این مورد نیز به‌منظور دسترسی به بهترین ساختار شبکه جهت پیش‌بینی، شبکه‌هایی با تعداد مختلف لایه‌های پنهان، توابع فعالسازی مختلف در لایه پنهان و قوانین مختلف یادگیری برآورد گردید. از میان قوانین محاسباتی الگوریتم یادگیری پس انتشار خطا، قوانین لونبرگ ماگوئان، دلتا بار دلتا، مونتومو کنچوگیت گرادینت انتخاب و تعداد نرون‌های لایه پنهان به روش آزمون و خطا تعیین گردید. به‌این منظور برای کلیه ساختارهای شبکه، تعداد نرون‌های پنهان از یک تا بیست تغییر داده شد تا این که تعداد نرون‌های لایه پنهان متناظر با بهترین معیار ارزیابی پیش‌بینی به‌دست آمده انتخاب گردید. تخمین‌ها نیز با سه شروع مجدد و ۱۰۰۰ تکرار انجام گردید. نتیجه گزارش شده برای هر ساختار بهترین نتیجه ممکن از سه بار شروع مجدد، ۱۰۰۰ تکرار و تعداد نرون بهینه برای آن ساختار در نظر گرفته شد. از میان ساختارهای مختلف، ساختاری انتخاب گردید که ضریب همبستگی بالاتر و کمترین خطای آموزش و آزمون را داشته باشد. برای سری



شکل ۴- مقادیر واقعی و برازش شده سری قیمت جهانی گندم برای داده‌های آزمون ARMA

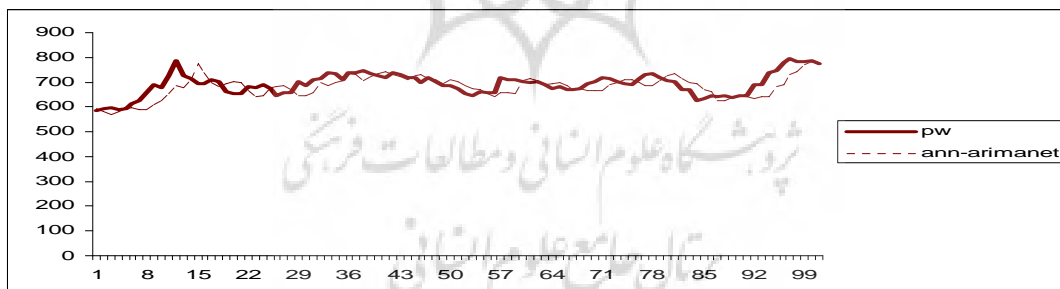


شکل ۵- مقادیر واقعی و برازش شده سری باقیمانده‌های الگوی ARMA برای داده‌های آزمون

جدول ۴- نتایج ارزیابی و مقایسه دقت پیش‌بینی الگوی تلفیقی شبکه عصبی مصنوعی و الگوی ARIMA

نام معیار	MAD	RMSE	MSE	نوع الگو
	۱۵.۳۷	۲۱.۰۶	۴۴۳.۷۵	الگوی تلفیقی ARMA-ANN

مأخذ: یافته‌های تحقیق



شکل ۶- مقادیر واقعی و برازش شده سری قیمت جهانی گندم الگوی تلفیقی برای داده‌های آزمون

همان‌طور که مشاهده می‌شود بر اساس کلیه معیارها دقت شبکه عصبی مصنوعی تلفیقی به‌طور قابل توجهی برتر از الگوهای آریمما و شبکه عصبی مصنوعی است. معیارهای خطای پیش‌بینی هر چه کمتر باشند نمایانگر پیش‌بینی دقیق‌تر هستند. اما هیچ‌یک از معیارهای فوق قادر نیستند برتری یک روش را به‌صورت آماری بررسی نمایند. از این‌رو با استفاده از آزمون ارائه‌شده توسط گرنجر نیوبولد به آزمون معنی‌داری اختلاف خطای الگوهای رقیب پرداخته می‌شود. آماره

جدول ۵- نتایج ارزیابی و مقایسه دقت پیش‌بینی الگوهای رقیب

نام معیار	MAD	RMSE	MSE	نوع الگو
	۱۷.۵۹	۲۲.۳۴	۴۹۹.۱	الگوی (۴، ۴) ARMA
	۱۶.۴۹	۲۲.۲۱	۴۹۸.۴۴	ANN
	۱۵.۳۷	۲۱.۰۶	۴۴۳.۷۵	الگوی تلفیقی ARMA-ANN

مأخذ: یافته‌های تحقیق

نتیجه‌گیری

این مطالعه با هدف شناسایی و برآورد مناسب‌ترین الگوی پیش‌بینی قیمت جهانی گندم اجرا شده‌است. به این منظور سه روش آریما، شبکه عصبی مبتنی بر آریما و تلفیق آریما و شبکه عصبی بررسی و از لحاظ معیارهای عملکرد با هم مقایسه شدند. نتایج نشانگر آن است که الگوی تلفیقی نسبت به الگوهای رقیب برتری داشته و به‌طور معنی داری دقت پیش‌بینی را بهبود می‌بخشد. این یافته با نتایج مطالعات (۳۴)، (۱۴)، (۲۸)، (۲۷) و (۲۲) مبنی بر برتری الگوهای تلفیقی مطابقت دارد. بر این اساس به‌کارگیری الگوهای تلفیقی، نظیر آنچه در مطالعه حاضر به‌کار گرفته شد، در پیش‌بینی قیمت محصولات کشاورزی (به‌ویژه محصولات استراتژیک) توصیه می‌شود.

محاسبه شده برای آزمون معنی‌داری اختلاف خطای دو روش پیش‌بینی الگوهای آریما و شبکه عصبی مصنوعی برابر با ۰/۰۹۵ به‌دست آمد که با توجه به مقدار t جدول، فرضیه صفر مبتنی بر برابری خطای دو روش رد نمی‌شود (جدول ۶). این بدان معنی است که دقت پیش‌بینی شبکه عصبی و الگوی آریما برآورد شده از نظر آماری معنی دار نمی‌باشد. این در حالی است که با توجه به آماره‌های محاسبه شده در جدول ۶ تفاوت دقت پیش‌بینی الگوی تلفیقی آریما و شبکه عصبی مصنوعی و الگوهای انفرادی آریما و شبکه عصبی مصنوعی از نظر آماری معنی دار بوده و دقت پیش‌بینی الگوی تلفیقی به‌طور معنی داری از الگوهای پایه و به‌طور مجزا برآورد شده آریما و شبکه عصبی مصنوعی بیشتر است.

جدول ۶- آزمون برابری خطای پیش‌بینی مرگان - گرنجر - نیبولد

الگو	ARMA(۴,۴)	ANN	ARMA(۴,۴)	ARMA-ANN
ARMA(۴,۴)	-	۰/۰۹۵	۸/۲۲***	
ANN	۰/۰۹۵	-	۷/۰۶	
ARMA-ANN	۸/۲۲***	۷/۰۶***	-	

* و ** و *** به ترتیب نمایانگر معنی دار بودن در سطح ۱۰، ۵، ۱ درصد است

مأخذ: یافته‌های تحقیق

منابع

- ۱- فرج زاده ز. و شاه ولی آ. ۱۳۸۸. پیش‌بینی قیمت محصولات کشاورزی مطالعه موردی پنبه، برنج و زعفران. فصلنامه اقتصاد کشاورزی و توسعه ۶۷: ۷۱-۴۳.
- ۲- فهیمی فر س.م. ۱۳۸۷. مقایسه کارایی مدل‌های عصبی-مصنوعی و خودرگرسیون در پیش‌بینی قیمت محصولات کشاورزی ایران، پایان‌نامه کارشناسی ارشد گروه اقتصاد کشاورزی، دانشگاه زابل.
- ۳- قاسمی ع، اسد پور ح. شاصادقی م. ۱۳۷۹. کاربرد شبکه عصبی در پیش‌بینی سری‌های زمانی و مقایسه آن با مدل ARIMA. پژوهشنامه بازرگانی. ۱۲۰: ۸۷-۱۴.
- ۴- قدیمی م. و مشیری س. ۱۳۸۱. مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی، مجموعه مقاله‌های اولین همایش معرفی و کاربرد مدل‌های ناخطی پویا و محاسباتی در اقتصاد، دانشگاه علامه طباطبایی، دانشکده اقتصاد، مرکز تحقیقات اقتصاد ایران.
- ۵- گیلان پور الف. و کهزادی ن. ۱۳۷۶. پیش‌بینی قیمت برنج در بازار بین‌الملل با استفاده از الگوی خودرگرسیونی میانگین متحرک. فصلنامه اقتصاد کشاورزی و توسعه ۸: ۲۰۰-۱۸۹.
- ۶- مجاوریان م. و امجدی الف. ۱۳۷۸. مقایسه روش‌های معمول با تابع مثلثاتی در قدرت پیش‌بینی سری‌های زمانی قیمت محصولات کشاورزی همراه با اثرات فصلی: مطالعه موردی مرکبات. فصلنامه اقتصاد کشاورزی و توسعه ۲۵: ۶۲-۴۳.
- ۷- مشیری س. ۱۳۸۰. پیش‌بینی تورم ایران با استفاده از مدل ساختاری، سری‌های زمانی و شبکه‌های عصبی، مجله تحقیقات اقتصادی. ۵۸: ۱۸۴-۱۴۷.
- ۸- مشیری س. و فروتن ف. ۱۳۸۳. آزمون آشوب و پیش‌بینی قیمت‌های آتی نفت خام، فصلنامه پژوهش‌های اقتصادی ایران. ۲۱: ۹۰-۶۷.
- ۹- مشیری س. و مروت ح. ۱۳۸۵. پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیرخطی. فصلنامه پژوهشنامه بازرگانی. ۴۱: ۲۷۰-۲۴۵.
- ۱۰- مقدسی ر. و رحیمی بدر ب. ۱۳۸۸. ارزیابی قدرت الگوهای مختلف اقتصادسنجی برای پیش‌بینی قیمت گندم. پژوهشنامه اقتصادی. ۲۶۳-

- ۱۱- نجفی ب.، زیبایی م.، شیخی م.م. و طرازکار م.ح. ۱۳۸۶. پیش‌بینی قیمت برخی محصولات کشاورزی در استان فارس: کاربرد شبکه عصبی مصنوعی. مجله علوم فنون و کشاورزی و منابع طبیعی. ۱۱: ۵۱۱-۵۰۱.
- ۱۲- یاعلی م.، محمدی ح. و فرج زاده ز. ۱۳۸۸. پیش‌بینی قیمت چغندر قند در ایران. مجله چغندر قند. ۲۵: ۹۷-۱۱۱.
- 13- Bates J.M., and Granger C.W.J. 1996. The combination of forecasts, *Oper. Res. Q.* 20:451-468.
- 14- Celmen R. 1989. Combining forecasts: a review and annotated bibliography with discussion, *Int. J. Forecasting.* 5: 559-608.
- 15- Cybenko G. 1989. Approximation by superpositions of a sigmoid function. *Mathematics of Control, Signals And System.* 2: 303- 314.
- 16- Denton J.W. How good are neural networks for causal forecasting? *J. Bus. Forecasting.* 14: 17-20.
- 17- Funahashi K. 1989. On the approximation realization of continuous mappings by neural networks. *Neural Network.* 2: 183-192.
- 18- Ginzburg, I., Horn, D. 1994. Combined neural networks for time series analysis, *Adv. Neural Int.J. Process. Systems.* 6: 224-231.
- 19- Greene, W.H. 2000. *Econometric Analysis.* 4th, Prentice Hall International Edition. New York university
- 20- Granger C.W.J. and Newbold P. 1977. *Forecasting economic time series.* Academic Press, Orlando. second edition
- 21- Haykin S. S. 1999. *Neural network: a comprehensive foundation.* Macmillan, New York.
- 22- Hoff J.L. 2003. Prediction of dose- time profiles for solar particle events using neural networks. Ph.D Thesis, The University of Tennessee, Knoxville.
- 23- Hornick K., Stinchcombe M., and White H. 1989. Multilayer feedforward networks are approximators, *Neural Network.* 2: 359-366.
- 24- Kim T.W. 2003. Nonparametric approaches drought characterization and forecasting. Ph.D Thesis. The University of Arizona.
- 25- Kohzadi N., Boyd M. S., Kermanshahi B. and Kaastra L. 1996. A comparison of artificial neural networks and time series model for forecasting commodity price. *Neurocomput.* 10: 169-181.
- 26- Luxloj J.T., Riis J.O., and Stensballe B. 1996. A hybrid econometric-neural network modeling approach for sales forecasting, *Int. J. Prob. Econ.* 43: 175-192.
- 27- Makridakis S., Chatfield C., Hibon M., Lawrence M., Miller T., Ord K. and Simmons L.F. 1993. The M-2 competition: a real-life judgmentally based forecasting study, *Int. J. Forecasting* 9: 5-29.
- 28- Markham S., and Rakes T.R. 1998. The effect of sample size and variability of data on the comparative performance of artificial neural networks and regression, *Compute. Oper.res.* 25: 251-263.
- 29- Plikan E., De Groot C., Wurtz D. 1992. Power consumption in West-Bohemia: Improved forecasts with decorrelating connectionist networks, *Neural Network* 2: 701-712.
- 30- Raknerud A., Skjerpen T. and Swensen A.R. 2007. A linear demand system within a seemingly unrelated time series equations framework. *Empirical Economics.* 32:105-124.
- 31- Reid D.J. 1968. Combining three estimates of gross domestic product, *Economica* 35: 431-444.
- 32- Tkacz G. 2001. Neural networks forecasting of Canadian GDP growth, *International Journal of Forecasting.* 17: 57-69.
- 33- Zhang P .G. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *NeuroComputing* 50:159-175
- 34- Wu Q. 2001. Data mining and knowledge discovery in financial research: Empirical investigations into currency. M.Sc Thesis. McGill University, Montreal.