



## رهیافت الگوسازی تلفیقی برای پیش‌بینی قیمت محصولات کشاورزی

رضا مقدسی<sup>۱\*</sup> - میترا ژاله رجبی<sup>۲</sup>

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 کفايت 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 هر زمان‌های 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 رقب مقایسه شده است. دقت پیش‌بینی الگوها با استفاده از معیارهای معمول نظیر RMSE، MSE و MAE و همچنین معنی‌داری اختلاف میان معیارهای فوق با استفاده از آماره گنجر و نیوبولد بررسی و آزمون شد. نتایج پیش‌بینی‌های قیمت گندم حاکی از آن است که الگوی تلفیقی به طور معنی‌داری دقت پیش‌بینی به دست 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 نمی‌باشد (۳۴). اخیراً الگوهای شبکه عصبی مصنوعی<sup>۱</sup> به طور 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 آریما و شبکه عصبی مصنوعی هیچ‌یک قادر به شناسایی و الگوسازی مناسب داده‌ها نخواهند بود. زیرا الگوی آریما 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 مکریداکیس 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 می‌باید. لیوکساج و همکاران (۲۷) به منظور پیش‌بینی مقادیر فروش، یک روش تلفیقی شبکه عصبی مصنوعی و اقتصاد سنجی و گینزبورگ و هرون (۱۹) تلفیق چند شبکه عصبی پیش‌خور<sup>۲</sup> 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 گرفته است. یکی از پرکاربردترین الگوهای پیش‌بینی سری زمانی، الگوی خود توضیح جمعی میانگین متحرک<sup>۳</sup> (ARIMA) می‌باشد که به‌دلیل ویژگی‌های آماری و روش معروف باکس جنکینز<sup>۴</sup> در طراحی مورد توجه خاص بوده است. علی‌رغم انعطاف‌پذیری الگوهای آریما<sup>۵</sup>، محدودیتی بر الگو متصور است و آن پیش‌فرض خطی بودن این الگوها است. در الگوهای آریما به‌دلیل فرض ساختار همبستگی خطی شده در مقادیر سری زمانی، فرم‌های

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

\*)- نویسنده مسئول:

3-Autoregressive Integrated Moving Average

4- Box-Jenkins

5- به منظور خودداری از تکرار کلمات اختصاری نظیر ARMA و ARIMA در این مقاله از معادل فارسی این واژه‌ها استفاده می‌گردد.

الگوهای پیش‌بینی سری‌های زمانی در اقتصاد سنجی است<sup>(۹)</sup>. 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 به عنوان مهم‌ترین منبع برای توضیح تغییرات متغیر استفاده نمود و پیش‌بینی را تهیه با استفاده از اطلاعات قبلی خود متغیر انجام داد. بر طبق این دیدگاه اگر بتوان فرآیند مولد یک متغیر را به دست آورد پیش‌بینی آن متغیر نسبتاً به راحتی امکان‌پذیر خواهد بود<sup>(۸)</sup>. فرآیند ARIMA(p,d,q) را می‌توان به صورت رابطه<sup>(۱)</sup> 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<sup>۲</sup> 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<sup>۳</sup> می‌شود. عموماً برای تخمین الگوی آریما از روش باکس-جنکیتز استفاده می‌شود که دارای چهار مرحله شناسایی، تخمین<sup>۴</sup>، تشخیص دقت پردازش<sup>۵</sup> و پیش‌بینی<sup>۶</sup> می‌باشد<sup>(۲۰)</sup>.

### 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 چارچوب‌های 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<sup>(۳۴)</sup>. شبکه عصبی پیش خور با یک لایه پنهان پرکاربردترین فرم الگو شبکه عصبی برای الگوسازی و پیش‌بینی سری‌های زمانی است<sup>(۳۵)</sup>. شبکه عصبی مصنوعی بدون توجه به نوع مسئله، 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 تعییر ساختار داده‌ها سازگارتر<sup>۷</sup> خواهد شد<sup>(۳۴)</sup>. تلفیق الگوهای پیش‌بینی از مطالعات رید<sup>(۳۲)</sup> و باتس و گرنجر<sup>(۱۳)</sup> آغاز شد و سلمان<sup>(۱۴)</sup> یک تجدید نظر جامع در این زمینه ارائه داد. ایده اصلی ترکیب الگوهای پیش‌بینی، به کارگیری ویژگی‌های الگوهای پایه به طور 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 دقیق ترین 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 به کارگیری 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<sup>(۲۶)</sup>، گیلان پور و کهزادی<sup>(۱)</sup>، مجاوریان و امجدی<sup>(۶)</sup>، قاسمی و همکاران<sup>(۴)</sup>، نجفی و همکاران<sup>(۱۱)</sup>، مقدسی و رحیمی بدر<sup>(۱۰)</sup>، فهیمی فر<sup>(۳)</sup>، فرخزاد و شاه ولی<sup>(۲)</sup> و یاعلی جهرمی و همکاران<sup>(۱۲)</sup> اشاره کرد. در کلیه این مطالعات الگوهای مختلف پیش‌بینی اقتصاد سنجی، سری زمانی و شبکه عصبی مصنوعی به طور مجزا و انفرادی الگوسازی و بعد از مقایسه و ارزیابی دقت پیش‌بینی، قیمت محصولات مختلف کشاورزی با دقیق ترین الگو پیش‌بینی شده است.

در ادامه به منظور 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 ذکور 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 این رو الگوی شبکه عصبی مصنوعی توضیح داده شده، یک فرم تابعی غیرخطی از مشاهدات گذشته ( $y_{t-p}, \dots, y_{t-1}, y_t$ ) به

مقادیر آتی  $y_t$  را نشان می‌دهد. به طوری که:

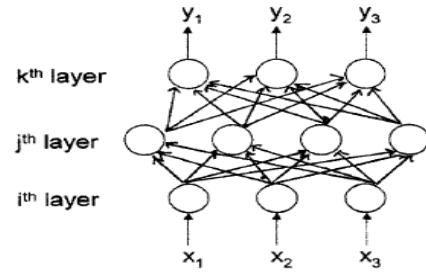
$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, w) + \varepsilon_t \quad (4)$$

که در آن  $w$  یک بردار از همه پارامترها و  $f$  یکتابع 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 به وسیله محقق یا پیش توضیحات مسئله مورد نظر، قبل از آموزش و آزمون شبکه عصبی انتخاب شوند. مطابق با قانون تقریب زننده جامع<sup>۱</sup>، یک شبکه عصبی مصنوعی صرفاً با یک لایه پنهان با دقت بالایی قادر به شناسایی روابط موجود در داده‌ها خواهد بود. اما ساینسکو<sup>(۱۵)</sup>، فاناهاشی<sup>(۱۸)</sup>، هورنیک و همکاران<sup>(۲۴)</sup> در مطالعات خود نشان دادند که در برخی شرایط، شبکه عصبی با یک لایه پنهان، ممکن است به لحظات روانی محاسباتی و تمییم 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 عور داده می‌شود تا خروجی را که به عنوان ورودی برای واحد دیگر محاسبه شود، تولید کند.

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

ممولاً از سه لایه ورودی<sup>۱</sup>، پنهان<sup>۲</sup> و خروجی<sup>۳</sup> تشکیل شده است. نرون‌های ورودی، سیگنال‌های خارجی را که به شبکه تقدیم می‌شود، دریافت می‌کنند. این سیگنال‌ها به وسیله وزن‌هایی<sup>۴</sup> تعدیل می‌شوند. مطابق این تعدیلات، در هر نرون خروجی، ورودی‌های موزون جمع زده می‌شوند و سپس این مجموع از طریق یک تابع فعالسازی<sup>۵</sup> عبور داده می‌شوند. خروجی تابع فعالسازی، خروجی موردنظر است<sup>(۲۲)</sup>. 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 می‌شوند. توضیحات ارائه شده یک شبکه پیش‌خور<sup>۶</sup> را معرفی می‌نماید. وقتی یک شبکه پیش‌خور نرون‌های پنهان را شامل شود، شبکه پرسپترون چند لایه<sup>۷</sup> نامیده می‌شود<sup>(۲۳)</sup>. 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

روابط بین خروجی<sup>۸</sup>  $y_t$  و ورودی ها<sup>۹</sup> ( $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ ) از رابطه ریاضی زیر تعیین 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  $\beta_{ij}$  ( $i=1,2,\dots,p$ ;  $j=1,2,\dots,q$ ) و  $\alpha_j$  ( $j=1,2,\dots,q$ ) 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 approximator

9- TPPT Learning

10- TPPT Training

11- TPPT Back Propagation

12- TPPT Feedforward

با  $n$  نرون ورودی، الگوی شبکه عصبی مصنوعی با قیماندها عبارت خواهد بود از:

$$e_i = f(e_{i-1}, e_{i-2}, \dots, e_{i-n}) + \varepsilon_i \quad (7)$$

که در آن  $f$  یکتابع غیرخطی تعیین شده توسط شبکه عصبی و  $\varepsilon_i$  خطای تصادفی است. با نشان دادن مقادیر پیش‌بینی از معادله (7) به صورت  $\hat{N}_i$ ، پیش‌بینی تلفیقی عبارت خواهد بود از:

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

به طور خلاصه، روش پیشنهادی سیستم تلفیقی شامل دو مرحله خواهد بود. در مرحله اول، یک الگوی آریما برای تجزیه و تحلیل بخش خطی مساله به کار می‌رود. در مرحله دوم، شبکه عصبی برای الگوسازی با قیماندهای الگوی آریما ساخته می‌شود. از آنجا که الگوی آریما قادر به شناسایی ساختار غیرخطی داده‌ها نیست، با قیماندهای 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 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 باشیت به طور مداوم آزمون شود. عملیات آزمون به وسیله عبور یک مجموعه داده مجزا تحت عنوان مجموعه آزمون<sup>۲</sup>، 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. به عبارت دیگر بعد از تخمین و آموزش شبکه، برای ارزیابی، باید قدرت پیش‌بینی شبکه در خارج از نمونه را بررسی کرد. برای این منظور معمولاً، داده‌ها را به دو مجموعه جدا تقسیم می‌کنند. بخش اول به مجموعه آموزش<sup>۳</sup> یا تخمین و مجموعه 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 به عبارت دیگر، توان تعمیم آن به خارج از مجموعه داده‌ای مورد استفاده در تخمین، ارزیابی می‌شود.

به منظور 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 می‌گردد. در مسیر پس خور<sup>۴</sup>، 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 تعدل می‌شوند. به طوری که پاسخ شبکه را به پاسخ دلخواه نزدیک‌تر سازد (۲۵).

#### الگوی تلفیقی ANN و ARIMA

الگوهای شبکه عصبی مصنوعی و آریما برای همه شرایط و همه روابط، الگوهای جامعی نبوده و تنها در محدوده خطی و غیرخطی خاص خود موفق عمل می‌کنند. تقریب الگوهای آریما 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 شبیه سازی شده نشان داد که در صورت وجود مشاهده دور افتاده یا هم خطی در داده‌ها، دقت شبکه عصبی مصنوعی به طور معنی‌داری بهتر از الگوهای رگرسیون خطی خواهد بود. مارخام و راکس (۳۹) نیز دریافتند که کارآیی شبکه عصبی برای مسائل رگرسیون خطی به اندازه نمونه و سطح آشفتگی بستگی دارد. از این‌رو به کارگیری کورکرانه شبکه عصبی مصنوعی برای هر نوع داده‌ای علاقه‌مند منطقی به نظر نمی‌رسد. از آنجا که آگاهی کامل از ویژگی‌های داده‌ها در مسائل واقعی مشکل است، روش تتفیق 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 کیم. به طوریکه:

$$y_i = L_i + N_i \quad (5)$$

$L_i$  جز خطی و  $N_i$  جز غیرخطی را نشان می‌دهد. این دو جز باشیت از داده‌ها شناسایی و تخمین زده شوند. ابتدا اجازه می‌دهیم تا آریما جز خطی را الگوسازی نموده، درنتیجه، با قیماندهای از الگوی خطی فقط روابط غیرخطی را شامل خواهد بود. اگر  $e_i$  با قیماندهای الگوی خطی را نشان دهند، آنگاه:

$$e_i = y_i - \hat{L}_i \quad (6)$$

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

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

به منظور استفاده از فرآیند آریما، پس از تعیین درجه هم‌جمعی (d)، تعداد جملات خود توضیح (p) و تعداد جملات میانگین متاخرک (q)، با بهره‌گیری از روش پسران و پسران (۱۹۷۷) و معیار آکائیک و شوارتر-بیزین، محاسبه شده و بر اساس کمترین آماره‌ها، فرآیندی با تعداد جملات خودتوضیح برابر با ۴ و میانگین متاخرک برابر با ۴ بهترین ساختار انتخاب شده است. بنابراین از میان حالت‌های مختلف، فرآیند ARMA(۴,۴) به عنوان بهترین حالت برای پیش‌بینی انتخاب گردید. بعد از بررسی کفايت الگو در مرحله بعد قیمت برای مجموعه آزمون ۷/۲۱ (۲۰۱۰/۱۰/۱۰) 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. معیارهای خطای پیش‌بینی برای داده‌های آزمون حاصل از الگوی ARMA(۴,۴) در

#### جدول ۲ خلاصه شده است.

مقادیر برآش 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 آریما می‌پردازد. در این نوع شبکه ورودی‌های شبکه به صورت وقفه‌های متغیر مورد نظر جهت پیش‌بینی بر اساس الگوی آریما تعیین می‌شود. بر اساس اصل تقریب‌زننده جامع، از شبکه پیش‌خور تعمیم‌یافته استفاده شده است. در این شبکه‌ها الگوریتم پسانشان خطا به عنوان الگوریتم آموزش و همان‌گونه که گفته شد وقفه‌های بر گرفته شده از الگوی آریما 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 فالسازی لایه پنهان توابع لجستیک شامل سیگموئید و تانژانت هیبریوپولیک و تابع فالسازی لایه خروجی تابع فالسازی خطی در نظر گرفته شد.

بر معیارهای متدالول از جمله، معیار میانگین مربع خطأ<sup>۱</sup>، ریشه میانگین مربع خطأ<sup>۲</sup> و معیار میانگین قدر مطلق خطأ<sup>۳</sup> روش ارائه شده توسط گرنجر و نیوبولد<sup>۴</sup> جهت آزمون معنی‌داری اختلاف خطای الگوهای رقیب نیز استفاده شده است. 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<sup>۵</sup> 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<sup>۶</sup> 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<sup>۷</sup> 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 قبل اذکر شد، به منظور مقایسه روش‌های معمول پیش‌بینی، داده‌ها به دو گروه آموزش و آزمون تقسیم می‌گردد. در این بخش از مطالعه از داده‌های ۲۰۱۰/۷/۲۱ تا ۲۰۰۸/۱۰/۳۰ به عنوان آموزش و از داده‌های ۲۰۱۰/۱۲/۱ تا ۲۰۱۰/۷/۲۱ جهت ارزیابی و آزمون الگو استفاده شده است. 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

6- برگفته 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 عرض از مبدأ و روند
قیمت گندم	۰/۹۹	۶۴۲۳ ***	۰	ایستا در سطح با عرض از مبدأ

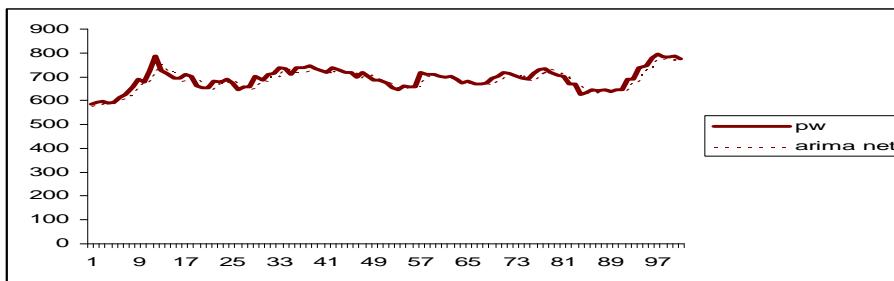
\* و \*\* و \*\*\* به ترتیب نمایانگر معنی دار بودن در سطح ۱، ۵، ۱۰ درصد است

مأخذ: یافته‌های پژوهش

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

MAD	RMSE	MSE	نام معیار نوع الگو
۱۷.۵۹	۲۲.۳۴	۴۹۹.۱	الگوی (۴,۴) ARMA

مأخذ: یافته‌های تحقیق



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

بالاتر و خطای آموزش و آزمون کمتر انتخاب گردید. بدین ترتیب از بررسی ساختارهای مختلف، شبکه عصبی مصنوعی پیش خور با دو لایه پنهان، ۱۵ نرون در لایه پنهان، تابع فعالسازی تانزانست هیبریوپولیک در لایه پنهان اول و تابع فعالسازی لجستیک در لایه پنهان دوم، با قانون یادگیری مومنتوم به عنوان ساختار بهینه الگوی شبکه عصبی مبتنی بر آریما 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- $ANN-GF(4-2-1)/lin$ ) در شکل ۳ نشان داده شده است.

### الگوی تلفیقی ANN و ARIMA

به منظور برآورد الگوی تلفیقی شبکه عصبی مصنوعی و آریما، ابتدا با استفاده از کل داده‌های قیمت گندم الگوی آریما برآورد و باقیمانده‌های برآورد بدست آمد. بر اساس معیار کمترین آماره اکائیک و شوارتر بیزین الگوی (۴,۴) ARMA 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 پس انتشار خط، قوانین لونبرگ ماگوئان<sup>۱</sup>، دلتا بار دلتا<sup>۲</sup>، مومنتوم<sup>۳</sup> و کچوگیت<sup>۴</sup> گرادینت 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 به دست آمده انتخاب گردید. از آنجاکه نتایج ممکن است با تکرار بیشتر و شروع آموزش شبکه با مقادیر اولیه مختلف بهمود یابد، عمل تحریم‌زدن 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، به منظور مقایسه الگوهای مختلف پیش‌بینی، داده‌های آموزش و آزمون مشابه هم در نظر گرفته شده‌اند. از میان ساختارهای مختلف، ساختاری با ضریب همیستگی

1- Levenberg-Maguan

2- Delta Bar Delta

3- Momentum

4- Conjugate Gradient

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

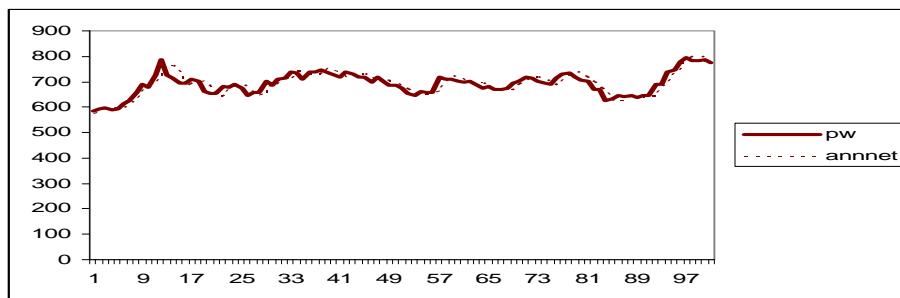
نام معیار	نوع الگو	تعداد نرون پنهان	شروع	تکرار	MSE	RMSE	MAD
		۱۵	۲	۱۶	۴۹۸.۴۴	۲۲.۲۱	۱۶.۴۹

مأخذ: یافته‌های تحقیق

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

نام معیار	نوع الگو	تعداد نرون پنهان	شروع	تکرار	MSE	RMSE	MAD
		۱۰	۲	۱۰۰	۴۴۳.۷۵	۲۱.۰۶	۱۵.۳۷

مأخذ: یافته‌های تحقیق



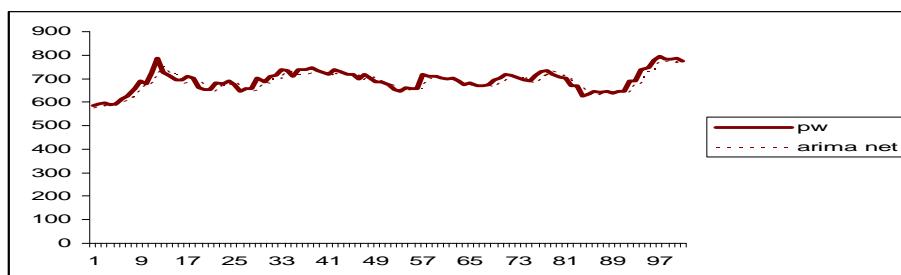
شکل ۳- مقادیر واقعی و برازش شده سری قیمت جهانی گندم برای داده‌های آزمون

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

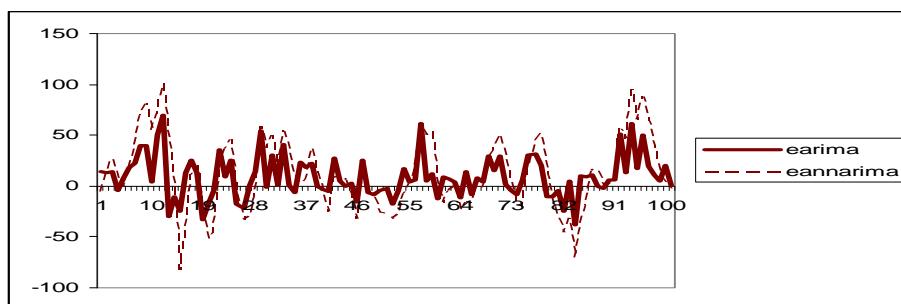
شکل‌های ۴ و ۵ نمودار مقادیر برازش شده و مقادیر واقعی سری زمانی قیمت‌های جهانی گندم برای داده‌های آزمون الگوی آریما و الگوی ANN-GF(4-2-1) (tan-sin-lin)m باقیمانده‌های آریما را نشان می‌دهد.

در مرحله بعد پیش‌بینی‌های الگوی آریما با پیش‌بینی‌های الگوی شبکه عصبی باقیمانده‌های الگوی آریما جمع‌زده می‌شود تا پیش‌بینی‌های الگوی تلفیقی به دست آید. نتایج دقت 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 تعمیم یافته به عنوان شبکه پایه و از الگوریتم پس انتشار خطاب به عنوان الگوریتم آموزش استفاده شد. اما در طراحی این شبکه نرون‌های ورودی نیز از یک تا ۵ تغییر یافته تا بهترین تعداد نرون ورودی تعیین گردد. در این مورد نیز به منظور دسترسی به بهترین ساختار شبکه جهت پیش‌بینی، شبکه‌هایی با تعداد مختلف لایه‌های پنهان، توابع فعالسازی مختلف مختلط در لایه پنهان و قوانین مختلف یادگیری برآورد گردید. از میان قوانین محسوباتی الگوریتم یادگیری پس انتشار خطاب، قوانین لونبرگ ماؤچان، دلتا بار دلتا، مومتوسون کنچوگیت گرادینت انتخاب و تعداد نرون‌های لایه پنهان به روش آزمون و خطاب تعیین گردید. به این 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 به دست آمده انتخاب گردید. نتیجه گزارش شده برای هر شروع مجدد و ۱۰۰۰ تکرار انجام گردید. نتیجه گزارش شده از سه 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 همسنگی بالاتر و کمترین خطای آموزش و آزمون را داشته باشد. برای سری



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

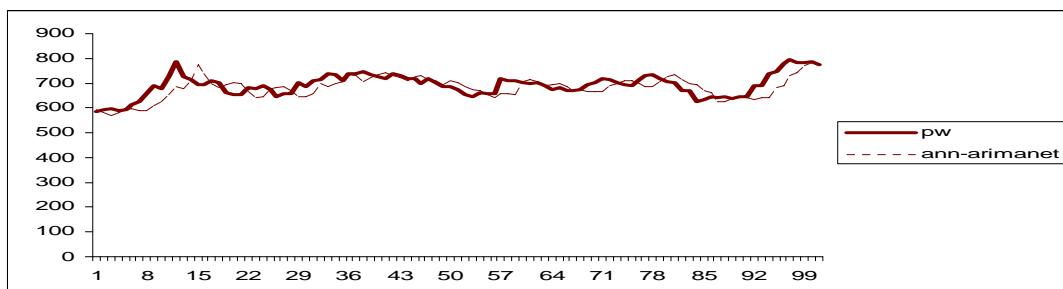


شکل ۵- مقادیر واقعی و برآذش شده سری باقیماندهای الگوی ARMA برای داده‌های آزمون

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

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

مأخذ: یافته‌های تحقیق



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

همان‌طور که مشاهده‌می‌شود بر اساس کلیه معیارها دقت شبکه عصبی مصنوعی تلفیقی به‌طور قابل توجهی برتر از الگوهای آریما 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 به صورت آماری ببررسی نمایند. از این‌رو با استفاده از آزمون ارائه شده توسط گرنجر نیوبولد به آزمون معنی‌داری اختلاف خطای الگوهای رقیب پرداخته می‌شود. آماره

جدول ۵- نتایج ارزیابی و مقایسه دقت پیش‌بینی الگوهای رقیب

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

مأخذ: یافته‌های تحقیق

### نتیجه‌گیری

این مطالعه با هدف شناسایی و برآورد مناسب‌ترین الگوی پیش‌بینی قیمت جهانی گندم اجرا شده است. به این منظور سه روش آریما، شبکه عصبی مبتنی بر آریما و تلفیق آریما و شبکه عصبی بررسی و از لحاظ میارهای عملکرد با هم مقایسه شدند. نتایج شناختگر آن است که الگوی تلفیقی نسبت به الگوهای رقیب برتری داشته و به طور 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 به کارگیری الگوهای تلفیقی، نظری آنچه در مطالعه حاضر به کار گرفته شد، در پیش‌بینی قیمت محصولات کشاورزی (به ویژه محصولات استراتژیک) توصیه می‌شود.

محاسبه شده برای آزمون معنی‌داری اختلاف خطای دو روش پیش‌بینی الگوهای آریما و شبکه عصبی مصنوعی برابر با ۰/۰۹۵ به دست آمد که با توجه به مقدار  $t$  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 آمارهای 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 به طور معنی داری از الگوهای پایه و به طور مجزا برآورد شده آریما و شبکه عصبی مصنوعی بیشتر است.

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

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

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

مأخذ: یافته‌های تحقیق

### منابع

- فرج زاده ز. و شاه ولی آ. ۱۳۸۸. پیش‌بینی قیمت محصولات کشاورزی مطالعه موردي پنبه، برنج و زعفران. . فصلنامه اقتصاد کشاورزی و توسعه ۶۷: ۴۳-۷۱.
- فهیمی فر س.م. ۱۳۸۷. مقایسه کارایی مدل های عصبی- مصنوعی و خود رگرسیونی در پیش‌بینی قیمت محصولات کشاورزی ایران، پایان نامه کارشناسی ارشد گروه اقتصاد کشاورزی، دانشگاه زابل.
- قاسمی ع، اسد پور ح. شاصادقی م. ۱۳۷۹. کاربرد شبکه عصبی در پیش‌بینی سری های زمانی و مقایسه آن با مدل ARIMA. پژوهشنامه بازارگانی. ۱۲۰: ۸۷-۱۴.
- قدیمی م. و مشیری س. ۱۳۸۱. مدل سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه های عصبی مصنوعی ، مجموعه مقاله‌های اولین همایش معرفی و کاربرد مدل‌های ناخطی پویا و محاسباتی در اقتصاد، دانشگاه علامه طباطبائی، دانشکده اقتصاد، مرکز تحقیقات اقتصاد ایران.
- گیلان پور الف. و کهزادی ن. ۱۳۷۶. پیش‌بینی قیمت برنج در بازار بین الملل با استفاده از الگوی خود رگرسیونی میانگین متحرک. فصلنامه اقتصاد کشاورزی و توسعه ۸: ۲۰۰-۱۸۹.
- مجاوریان م. و امجدی الف. ۱۳۷۸. مقایسه روش های معمول با تابع مثلثاتی در قدرت پیش‌بینی سری زمانی قیمت محصولات کشاورزی همراه با اثرات فصلی: مطالعه موردي مرکبات. فصلنامه اقتصاد کشاورزی و توسعه ۲۵: ۶۲-۴۳.
- مشیری س. ۱۳۸۰. پیش‌بینی تورم ایران با استفاده از مدل ساختاری، سری های زمانی و شبکه‌های عصبی ، مجله تحقیقات اقتصادی. ۵۸: ۱۸۴-۱۸۷.
- مشیری س. و فروتن ف. ۱۳۸۳. آزمون آشوب و پیش‌بینی قیمت های آتی نفت خام ، فصلنامه پژوهش های اقتصادی ایران. ۲۱: ۹۰-۶۷.
- مشیری س. و مروت ح. ۱۳۸۵. پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل های خطی و غیرخطی. فصلنامه پژوهشنامه بازارگانی. ۴۱: ۲۷۰-۲۴۵.
- مقسی ر. و رحیمی بذر ب. ۱۳۸۸. ارزیابی قدرت الگوهای مختلف اقتصادستجی برای پیش‌بینی قیمت گندم. پژوهشنامه اقتصادی. ۲۶۳-

۲۳۹

- 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 ج. ۱۳۸۸. پیش‌بینی قیمت چندرقند در ایران. مجله چندرقند. ۲۵: ۱۱۱-۹۷.
- 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. 4<sup>th</sup>, 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.