

اقتصاد کشاورزی و توسعه، سال بیست و یکم، شماره ۸۳، پاییز ۱۳۹۲

پیش بینی قیمت گوجه فرنگی: مقایسه روشهای تلفیقی شبکه عصبی - خودرگرسیونی و ARIMA

ولی بریم نژاد*، ملیحه بکشلو**

تاریخ دریافت: ۹۰/۱۱/۷ تاریخ پذیرش: ۹۱/۸/۲۴

چکیده

در این مطالعه کارایی روش ARIMA و شبکه عصبی خودرگرسیونی در پیش بینی قیمت خرده فروشی محصول گوجه فرنگی مقایسه شدند. داده‌های مورد استفاده شامل قیمت‌های هفتگی خرده فروشی گوجه فرنگی طی سالهای ۱۳۸۸ تا ۱۳۸۹ بوده که از سازمان میادین میوه و تره بار تهران گردآوری شد. نتایج مطالعه نشان داد که مدل غیرخطی شبکه عصبی خودرگرسیونی (NNAR) در پیش بینی قیمت خرده فروشی گوجه فرنگی دارای خطای پایین تر است و در نتیجه کاراتر از ARIMA عمل می کند.

طبقه بندی JEL: C22، C45، C53، Q11

* دانشیار گروه اقتصاد کشاورزی، دانشگاه آزاد اسلامی، واحد کرج (نویسنده مسئول)

e-mail: vali_borimnejad@kiauo.ac.ir

** دانشجوی کارشناسی ارشد اقتصاد کشاورزی، دانشگاه آزاد اسلامی، واحد کرج

کلید واژه‌ها:

پیش‌بینی، قیمت، گوجه فرنگی، شبکه عصبی خود رگرسیون^۱، ARIMA

مقدمه

تولید در بخش کشاورزی با شوکهای تصادفی و پیش‌بینی ناپذیر ناشی از شرایط آب و هوایی، آفت و سایر بلاای طبیعی همچون آتش‌سوزی روبه‌روست. از طرفی این شوکها قیمت محصولات کشاورزی، عملکرد بخش کشاورزی و نیز رفاه مصرف‌کنندگان را به شدت تحت تأثیر قرار می‌دهد و در نتیجه، نوسانهای قیمتی که محصولات کشاورزی در معرض آن قرار دارد و هم تولید کنندگان و هم مصرف کنندگان را تهدید می‌نماید. تغییر قیمت‌های کشاورزی می‌تواند پیامدهای اقتصادی-اجتماعی گسترده‌ای داشته باشد. تأثیر فوری این تغییرات متوجه مصرف مواد غذایی و تولید محصولات کشاورزی است. مطالعه روند شاخص قیمت مصرف‌کننده گوجه‌فرنگی در ماه‌های برداشت و غیربرداشت محصول نشان می‌دهد شاخص قیمت خرده‌فروشی گوجه‌فرنگی در سال ۱۳۸۹ از خرداد تا آذر با نوسان ۳/۵ برابری مواجه بوده است (قلی‌پور، ۱۳۹۱). بر این اساس، بررسی نوسانات قیمتی محصولات کشاورزی و پیش‌بینی دقیق آن می‌تواند موجب انتخاب نوع محصول و سطح زیر کشت مناسب آن و باعث تخصیص بهینه منابع، افزایش کارایی، افزایش مطلوبیت زراعت و در نهایت افزایش درآمد آنها می‌گردد؛ چرا که به طور کلی نقش راهنما را در جریان تولید و مصرف کالاها بر عهده دارند. پیش‌بینی قیمت محصولات کشاورزی علاوه بر کمک به درآمد زراعت کمک زیادی نیز به عوامل بازاریابی این بخش، به ویژه انبارداری، می‌کند و عنصر کلیدی در تصمیم‌گیری آنها می‌باشد. به علاوه پیش‌بینی قیمت می‌تواند نقش مؤثری در اتخاذ سیاست‌های دولت داشته باشد، زیرا دولتها، سیاست‌های خود را بر اساس پیش‌بینی‌های کوتاه‌مدت و بلندمدت از متغیرهای کلیدی اقتصادی، اتخاذ و اجرا می‌کنند (Dillon & Hardaker, 1993).

پیش‌بینی قیمت گوجه‌فرنگی.....

در این میان بررسی محصولاتی که دارای بیشترین نوسان هستند، ضروری‌تر می‌باشد. گوجه‌فرنگی جزء محصولاتی است که در سالهای اخیر و همچنین در طول سال نوسانات نسبتاً زیادی داشته است. امروزه روشهای جدیدتری برای پیش‌بینی روند سریهای زمانی ابداع شده است. در یک دسته از این روشها که به شبکه‌های عصبی مصنوعی موسومند، با استفاده از هوش مصنوعی، روابط پیچیده بین متغیرها فرا گرفته می‌شود. محققان اقتصادی بر این باورند که شبکه‌های عصبی می‌توانند هم در تحلیلهای خرد و هم در تحلیلهای کلان با پتانسیلی آشکار برای اصلاح و بهبود کیفیت پیش‌بینی‌های اقتصادی، به ویژه در مواردی که ارتباط غیر خطی معنی‌داری بین متغیرهای مستقل و وابسته وجود داشته باشد، مورد استفاده قرار گیرند. شایان ذکر است که این شبکه‌ها بهتر است به عنوان یک مکمل قدرتمند برای روشهای استاندارد اقتصادسنجی استفاده شوند نه اینکه به طور کامل جانشین آنها شوند (قاسمی و همکاران، ۲۰۰۰).

اغلب پدیده‌های طبیعی رفتاری غیرخطی دارند که لازمه تشخیص مناسب آنها، استفاده از مدل‌های غیرخطی است. همچنین در اکثر مطالعات، از فنون رگرسیون خطی یا چندجمله‌ای، میانگین متحرک، مدل‌های باکس و جنکینز، مدل‌های ساختاری و مدل‌های سری زمانی به منظور پیش‌بینی‌های متغیرهای اقتصادی استفاده می‌شود. اما این مدل‌ها از ضعفهایی برخوردارند که به محقق اجازه نمی‌دهند تا عوامل پیچیده و غیرخطی مؤثر بر پیش‌بینی را در نظر بگیرد (Racine, 2001). علاوه بر این، اخیراً به خوبی اثبات شده که بسیاری از مشاهدات سری زمانی اقتصادی، غیرخطی بوده و تخمین مدل‌های خطی برای مسائل پیچیده در دنیای واقعی همیشه رضایت بخش نیست. در این میان، کهنزادی و همکاران (Kohzadi et al., 1995) در مطالعه‌ای به پیش‌بینی قیمت گندم و گاو زنده با استفاده از شبکه‌های عصبی پیش‌خور و مدل ARIMA برای دوره زمانی ۱۹۹۰-۱۹۵۰ پرداختند و دریافتند خطای پیش‌بینی شبکه عصبی کمتر از مدل ARIMA است. در مطالعه‌ای دیگر، کومار و والیا (Kumar and Walia, 2006) برای بهینه‌سازی عرضه پول نقد، تقاضای آن را با استفاده از مدل‌های شبکه عصبی مصنوعی و سریهای زمانی بر اساس داده‌های حقیقی پول نقد یکی از

شعب بانکها در هندوستان برای دوره زمانی ۲ آوریل تا ۳۰ ژوئن ۲۰۰۴ پیش‌بینی کردند. نتایج نشان داد که شبکه عصبی مصنوعی عملکردی بهتر از روشهای سری زمانی دارد. همچنین قاسمی و همکاران (۲۰۰۰) به پیش‌بینی قیمت شیر با استفاده از شبکه‌های عصبی مصنوعی و مدل ARIMA پرداختند و دریافتند که خطای پیش‌بینی مدل شبکه عصبی ۹ تا ۲۲ درصد کمتر از مدل ARIMA است. طیبی و همکاران (۱۳۸۸) در یک مطالعه، قیمت گوشت مرغ را در ایران با استفاده از شبکه‌های عصبی مصنوعی و روش ARIMA برآورد کرده و دو روش را مورد مقایسه قرار دادند. نتایج حاکی از آن است که شبکه عصبی مصنوعی در تمام افقهای زمانی، دقیقتر از روش ARIMA عمل می‌کند. فهیمی فرد و همکاران (۱۳۹۰) به مقایسه توان پیش‌بینی مدل عصبی-فازی ANFIS با مدل شبکه عصبی ANN و خود رگرسیون ARIMA در قیمت هفتگی تخم مرغ پرداختند. نتایج نشان داد که مدل‌های ANN و ANFIS در مقایسه با مدل ARIMA و مدل ANFIS در مقایسه با مدل ANN در همه افقهای زمانی از کارایی بیشتری در پیش‌بینی قیمت تخم مرغ برخوردارند. فرج زاده و شاه ولی (۱۳۸۸) قیمت محصولات کشاورزی (پنبه و برنج و زعفران) را پیش‌بینی کردند. نتایج نشان داد بهترین پیش‌بینی برای سریهای قیمت اسمی و واقعی پنبه، به ترتیب با استفاده از الگوهای شبکه عصبی مصنوعی و هارمونیک به دست می‌آید. در کل، مطالعات و بررسیها نشان می‌دهد که مدل‌های عصبی در مقایسه با مدل‌های خطی از عملکرد بهتری برخوردارند.

هدف از این مطالعه مقایسه روش خطی ARIMA و روش غیر خطی تلفیقی شبکه عصبی - خود رگرسیونی به منظور انتخاب روشی است که کمترین خطا را در پیش‌بینی قیمت محصول گوجه فرنگی نشان می‌دهد.

مواد و روشها

در حالت کلی می‌توان روشهای معمول پیش‌بینی را به دو دسته رگرسیونی و غیر رگرسیونی تقسیم‌بندی نمود. روشهای غیر رگرسیونی شامل روش میانگین متحرک و انواع روشهای تعدیل نمایی است. روشهای رگرسیونی نیز به دو گروه علی و غیر علی تقسیم‌بندی

پیش‌بینی قیمت گوجه‌فرنگی.....

می‌شوند. از جمله روشهای رگرسیون علی می‌توان به مدل خودرگرسیون با واریانس ناهمسان شرطی^۱ و از جمله روشهای رگرسیون غیرعلی می‌توان به فرایند ARIMA و ARMA اشاره نمود (نجفی و همکاران، ۱۳۸۶). اما امروزه روش جدیدتری نیز برای پیش‌بینی ابداع شده که به رویکرد شبکه عصبی معروف است. گفتنی است موفقیت شبکه های عصبی به عنوان ابزاری قدرتمند به منظور تجزیه و تحلیل داده‌ها، موجب شده است تا توجه اقتصاددانان به این روش پیش‌بینی جلب شود و در اواخر دهه ۸۰ میلادی مدل‌های مختلفی جهت پیش‌بینی متغیرهای اقتصادی ساخته شود (فهمی فرد و همکاران، ۱۳۹۰).

در بسیاری از مطالعات انجام شده، روش ARIMA بر دیگر روشهای خطی پیش‌بینی برتری داشته است. لذا در این مطالعه به بررسی روش خطی ARIMA و روش غیر خطی شبکه عصبی خود رگرسیونی پرداخته می‌شود.

الگوی خود رگرسیون میانگین متحرک (ARIMA)

به طور کلی، فرایندی را $ARMA(p, q)$ گویند که شامل p مرتبه جمله خود رگرسیون و q مرتبه جمله میانگین متحرک باشد (به عبارت دیگر، شامل p مرتبه جمله با وقفه از متغیر وابسته و q مرتبه جمله با وقفه از جملات اخلاص باشد). همچنین اگر یک سری زمانی پس از d مرتبه تفاضل‌گیری ساکن شود و سپس توسط فرایند $ARMA(p, q)$ مدل‌سازی گردد در این صورت سری زمانی اصلی، سری زمانی خود رگرسیونی میانگین متحرک انباشته $ARIMA(p, d, q)$ است (گجراتی، ۱۹۹۵).

فرایند $ARIMA(p, d, q)$ برای متغیر x را می‌توان به صورت زیر نشان داد:

$$Y_t = f(t) + \sum \phi_i Y_{t-i} + \sum \theta_j \varepsilon_{t-j} + \varepsilon_t$$

که در آن Y_t ، ε_t ، ϕ و θ به ترتیب قیمت خرده‌فروشی محصول (در اینجا گوجه‌فرنگی)، درجه خود رگرسیونی، درجه میانگین متحرک، ضریب خود رگرسیونی و ضریب میانگین متحرک است و $f(t)$ روند زمانی را در صورت وجود در Y_t برآورد می‌کند.

1. Auto Regressive Conditional Heteroscedasticity (ARCH)

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی همانند مغز انسان عمل می‌کنند و ساختاری شبیه به آن دارند. مغز انسان به عنوان یک سیستم پردازش اطلاعات، از عناصر اصلی ساختاری به نام نرون تشکیل شده است. شبکه‌های عصبی مصنوعی نیز شامل مجموعه‌ای از نرون‌های به هم متصل می‌باشند که به هر مجموعه از این نرون‌ها یک لایه گفته می‌شود. نرون یا گره، کوچکترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد (منهاج، ۱۳۷۷).

شبکه‌های عصبی علی‌رغم تنوع، از ساختار مشابهی برخوردارند. شبکه‌های عصبی معمولاً از سه لایه ورودی، پنهان و خروجی تشکیل شده است. لایه ورودی فقط اطلاعات را دریافت می‌کند و مشابه متغیر مستقل عمل می‌نماید و لذا تعداد نرون‌های لایه ورودی بستگی به تعداد متغیرهای مستقل دارد. لایه خروجی نیز همانند متغیر وابسته عمل کرده و تعداد نرون‌های آن بستگی به تعداد متغیرهای وابسته دارد؛ اما برخلاف لایه‌های ورودی و خروجی، لایه پنهان هیچ مفهومی را نشان نمی‌دهد و صرفاً یک نتیجه میانی در فرایند محاسبه ارزش خروجی است (قدیمی و مشیری، ۱۳۸۱).

معمولاً در شبکه‌های عصبی، کل داده‌های در دسترس، به دو مجموعه آموزشی^۱ و مجموعه آزمایشی^۲ طبقه‌بندی می‌شوند. مجموعه آموزشی با الگوریتم یادگیری برای تخمین وزن‌های شبکه به کار می‌رود و مجموعه آزمایشی برای ارزیابی دقت پیش‌بینی شبکه آموزش دیده مورد استفاده قرار می‌گیرد. به طور کلی، برخی نقاط قوت شبکه‌های عصبی را می‌توان به شرح زیر دانست:

۱. با موفقیت می‌توان ارتباطات غیرخطی را مدلسازی کرد. در برخورد با ارتباطات غیرخطی، شبکه‌های عصبی با توابع محرک غیرخطی بهتر از مدل‌های رگرسیون خطی عمل می‌کنند.

1. Training Set
2. Testing Set

پیش‌بینی قیمت گوجه‌فرنگی.....

۲. شبکه‌های عصبی از انعطاف‌پذیری تابعی ساختار شبکه ناشی می‌شود. در شبکه‌های عصبی طیف گسترده‌ای از تکنیک‌های آماری مانند رگرسیون خطی، مدل پرویت مضاعف، مدل‌های خود توضیحی و غیره را می‌توان برای ایجاد اصلاحات در توابع محرک و ساختار شبکه (مانند تغییر نرونها در هر لایه) مورد استفاده قرار گیرند.

شبکه‌های پویا یک بخش خطی خودرگرسیونی (AR) و یک بخش غیرخطی شبکه عصبی پیشخور انتشار برگشتی (ANN) ^۱ دارد که با استفاده از این شبکه‌ها امکان دستیابی به مدل‌های پرت‌تر از هر دو نوع مدل‌های خطی و شبکه‌های عصبی انتشار برگشتی وجود دارد (Forsgren & Kling, 2003).

یکی از رهیافتهایی که برای ساخت مدل‌های پویای غیرخطی با استفاده از شبکه‌های عصبی به کار می‌رود، اضافه کردن مدل AR به یک مدل شبکه عصبی برای تشکیل شبکه عصبی خود رگرسیونی (NNAR) به صورت زیر می‌باشد:

$$\hat{Y}(t) = f[y(t-1), y(t-2), \dots, y(t-n_y)]$$

که در آن f یک نگاشت انجام گرفته بوسیله شبکه عصبی می‌باشد (Medsker & Jain, 2000). ورودی شبکه عصبی، وقفه‌های مقادیر واقعی هدف $y(t)$ می‌باشد و n_y مقادیر واقعی هدف است که توسط سیستم تعیین می‌شود. ساختار شبکه عصبی پویا چنین است:



شکل ۱. ساختار NNAR


نحوه آموزش در این نوع شبکه مبتنی بر قانون یادگیری اصلاح خطاست. در این روش، آموزش با استفاده از مجموعه وزنه‌های تصادفی اولیه آغاز می‌شود (Haykin, 1994).

1-Artificial Neural Network

2. Target

تابع آموزش این شبکه Levenberg-Marquardt (LM) ^۱ و تابع یادگیری آن، GDM ^۲ می باشد و برای لایه خروجی، تابع فعال سازی خطی به کار رفت. طراحی بخش خطی (AR) این مدل توسط خود سیستم انجام می گیرد. در نهایت، برای بررسی کارایی مدل، داده های خروجی شبکه با داده های واقعی مقایسه گردید. LM تابع آموزشی است که مقادیر وزنها و اربها را براساس روش بهینه سازی Levenberg-Marquardt بهنگام می کند (Medsker & Jain, 2000). تابع کارایی خطی پیش فرض این شبکه، میانگین مجذور خطا می باشد.

شکل ۲ مدل NNAR به کاررفته در این مطالعه را نشان می دهد:



شکل ۲. مدل پویای شبکه عصبی خود رگرسیون (NNAR)

در این مطالعه، در تمامی مدلها قیمت خرده فروشی گوجه فرنگی به عنوان تابعی از مقادیر گذشته آن مدل سازی شد. داده های به کار رفته در این مطالعه به صورت کتابخانه ای گردآوری شد. برای برآورد مدل خطی از نرم افزار Eviews و برای حل مدل شبکه عصبی از نرم افزار MATLAB استفاده گردید.

بررسی قدرت پیش بینی

به منظور مقایسه قدرت پیش بینی، از معیارهای مختلف و از جمله میانگین قدر مطلق خطا^۱، میانگین مجذور خطا^۲، ریشه میانگین مربعات خطا^۲ و شاخص درصد میانگین مطلق خطا^۳ استفاده گردید. این معیارها را می توان به صورت روابط زیر نشان داد (Haykin, 1994):

1. Levenberg, (1944) & Marquardt, (1963)
2. Gradient Descent With Momentum Weight/bias Learning Function
3. Mean Absolute Error

پیش‌بینی قیمت گوجه‌فرنگی.....

$$MAE = \sum_{i=1}^n \frac{|e_i|}{n}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{y_i} \right| \times 100$$

$$MSE = \sum_{i=1}^n \frac{e_i^2}{n}$$

$$RMSE = \sqrt{\sum_{i=1}^n \frac{e_i^2}{n}}$$

در این روابط n تعداد پیش‌بینی، e_i خطای پیش‌بینی i ام است که از تفاوت مقادیر

پیش‌بینی شده و مقادیر واقعی به دست می‌آید.


در این مطالعه از داده‌های هفتگی دیماه ۱۳۸۸ تا فروردین سال ۱۳۹۰ استفاده شد. علاوه بر این، گرچه اجماع کلی در مورد چگونگی تقسیم داده‌ها در مدل‌های عصبی-مصنوعی وجود ندارد، اما تمامی مطالعات، بخش عمده داده‌ها (معمولاً ۷۰٪، ۸۰٪ یا ۹۰٪) را به آموزش و باقیمانده داده‌ها را به آزمون مدل‌ها اختصاص می‌دهند (Haoffi et al., 2007). در این مطالعه ۷۰٪ داده‌ها به آموزش و ۳۰٪ داده‌ها به آزمون خروجی مدل NNAR اختصاص داده شد.

نتایج و بحث

بررسی کارایی مدل NNAR در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی

به منظور بررسی کارایی این مدل در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی، ابتدا به منظور نرمال‌سازی داده‌های سری زمانی با استفاده از روش هایکین، داده‌ها به اعداد بین ۰ و ۱+ (logisig) تبدیل می‌شود (Haoffi et al., 2007). همچنین برای طراحی شبکه، از ساختارهای مختلف شبکه انتشار برگشتی پیش‌خور با تابع آموزشی LM با تکرار $Epoch=100$ ، تابع یادگیری GDM و تابع فعال‌سازی خطی برای لایه خروجی، استفاده گردید. طراحی بخش خطی (AR) این مدل توسط خود سیستم صورت می‌گیرد. در نهایت برای بررسی کارایی مدل، داده‌های خروجی شبکه با داده‌های واقعی مقایسه شد.

1. Mean of Square Error
2. Root Mean Square Error
3. Mean Absolute Percentage Error



نمودار ۱. نتایج پیش‌بینی قیمت با استفاده از فرایند NNAR و مقایسه آن مقادیر حقیقی

جدول ۱. بررسی کارایی مدل NNAR در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی

MAPE	MAE	RMSE	معیار خطا
۴/۸	۲۰۸/۰۲	۳۵۳/۱	مقدار

مأخذ: یافته‌های تحقیق


بررسی کارایی مدل ARIMA در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی

به منظور تعیین کارایی مدل ARIMA در پیش‌بینی سری زمانی مذکور، ابتدا ایستایی سری زمانی با آزمون دیکی فولر تعمیم یافته (ADF)^۱ بررسی شد. نتایج نشان می‌دهد که درجه ایستایی (d) برای سری زمانی مورد بررسی برابر ۲ می‌باشد، یعنی سری زمانی بعد از ۲ مرتبه تفاضل‌گیری ایستا می‌شود. همچنین با توجه به اینکه مقدار آماره ADF برابر با $-۴/۲$ و کمتر از مقادیر بحرانی جدول است، بنابراین متغیر مزبور در هر ۳ سطح اطمینان ایستا شده است.

1. Augmented Dicky-Fuller

پیش‌بینی قیمت گوجه‌فرنگی.....

سپس با استفاده از معیارهای AC و PAC به ترتیب بهترین مرتبه p و q مشخص می‌شود و لذا از آنجا که حدهای اعتماد تقریبی (فاصله اطمینان) ۹۵٪ بین ۰/۲۰۸۹ و ۰/۲۰۸۹- می‌باشند (گجراتی، ۱۹۹۵)، جهت پیش‌بینی قیمت گوجه‌فرنگی فرایند (۱و۲) ARIMA به عنوان بهترین حالت انتخاب شد.



نمودار ۲. نتایج پیش‌بینی قیمت با استفاده از فرایند ARIMA و مقایسه آن با مقادیر حقیقی

جدول ۲. بررسی کارایی مدل ARIMA در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی

MAPE	MAE	RMSE	معیار خطا
۷/۹	۴۰۱/۰۵	۶۱۳/۱	مقدار

مأخذ: یافته‌های تحقیق

شرط لازم برای کارا تر بودن یک مدل نسبت به مدل دیگر، کوچکتر از یک بودن کمیت حاصل از تقسیم RMSE, MAE یک مدل بر مدل دیگر است. در جدول ۳ نتایج حاصل از مقایسه کارایی مدل‌های مذکور در پیش‌بینی قیمت گوجه‌فرنگی ارائه شده است.

جدول ۳. مقایسه کارایی مدلها در پیش بینی قیمت گوجه فرنگی

مدلها	MAE	RMSE
NNAR	۲۰۸/۰۲۶	۳۵۳/۱۱۸
ARIMA	۴۰۱/۰۵	۶۱۳/۱۷
نسبت	۰/۵۱۹	۰/۵۷۶

مأخذ: یافته‌های تحقیق

کمیت حاصل از تقسیم MAE, RMSE مدل NNAR بر مدل ARIMA کوچکتر از یک و به ترتیب برابر ۰/۵۷۶ و ۰/۵۱۹ می‌باشد، بنابراین، مدل NNAR در مقایسه با مدل ARIMA، داده‌های حقیقی را با خطای کمتری شبیه‌سازی می‌کند.

این نتایج با یافته‌های خلیق و مقدسی (۱۳۸۷) مطابقت دارد. آنها در یک مطالعه، قیمت گوجه فرنگی را با استفاده از مدل شبکه عصبی و الگوهای سری زمانی پیش‌بینی کردند و این الگوها را با هم مورد مقایسه قرار دادند. نتایج حاصل مؤید برتری شبکه‌های عصبی مصنوعی در پیش‌بینی قیمت محصول مورد مطالعه بر الگوهای سری زمانی است.

نتیجه‌گیری و پیشنهاد

گرچه روش ARIMA به عنوان رایجترین روش خطی پیش‌بینی، نقشی اساسی ایفا می‌نماید، ولی نتایج مطالعه نشان داد روش شبکه عصبی مصنوعی ابزار قدرتمندی در پیش‌بینی قیمت است و چون در آن آموزش تکرار می‌شود، در به حداقل رساندن خطای پیش‌بینی تواناست. براساس نتایج، مدل شبکه عصبی خود رگرسیون بر مدل ARIMA در پیش‌بینی قیمت خرده‌فروشی گوجه فرنگی برتری دارد؛ بنابراین می‌توان پیشنهادهای زیر را ارائه داد:

۱. تأکید بر استفاده از روش شبکه‌های عصبی مصنوعی در پیش‌بینی قیمت محصولات

کشاورزی در کنار سایر مدل‌های متداول پیش‌بینی؛

پیش‌بینی قیمت گوجه‌فرنگی.....

۲. شبکه‌های عصبی با محدودیتهایی از جمله فقدان یک تنوری جامع روبه روست و از طرفی وزنه‌های شبکه‌های عصبی مانند ضرایب مدلهای رگرسیون، قابل تفسیر نیست و بنابراین، پیشنهاد می‌شود این شبکه‌ها برای پیش‌بینی به کار رود نه برای تحلیلهای سیاستی.

منابع

۱. اثنی‌عشری، ه. ۱۳۸۶. تأثیر سیاستهای پولی و مالی بر اشتغال بخش کشاورزی ایران. پایان‌نامه کارشناسی ارشد. دانشکده کشاورزی. دانشگاه زابل.
۲. جهرمی، م. محمدی، ح. و فرج‌زاده، ز. ۱۳۸۶. پیش‌بینی قیمت چغندر قند در ایران، مجله چغندر قند، شماره ۲۵.
۳. خلیق، پ. و مقدسی، ر. ۱۳۸۷. پیش‌بینی قیمت محصول گوجه‌فرنگی به کمک الگوهای شبکه عصبی مصنوعی و سری زمانی. اولین کنگره ملی فناوری تولید و فرآوری گوجه‌فرنگی. ص ۹۷ تا ۱۱۱.
۴. طیبی، س. ک.، آذربایجانی، ک. و بیاری، ل. ۱۳۸۸. مقایسه مدلهای شبکه عصبی مصنوعی و سریهای زمانی برای پیش‌بینی قیمت گوشت مرغ در ایران. پژوهشنامه علوم اقتصادی، ۱: ۷۳ - ۹۶.
۵. فرج‌زاده، ز.، شاه‌ولی، ا. ۱۳۸۸. پیش‌بینی قیمت محصولات کشاورزی مطالعه موردی پنبه و برنج و زعفران. مجله اقتصاد کشاورزی و توسعه، ۶۷: ۴۳ - ۷۱.
۶. فهیمی‌فرد، س. م.، سالارپور، م. و صیوحی، م. ۱۳۹۰. مقایسه توان پیش‌بینی مدل عصبی-فازی ANFIS با مدل شبکه عصبی ANN و خود رگرسیونی ARIMA (مطالعه موردی قیمت هفتگی تخم مرغ)، مجله اقتصاد کشاورزی و توسعه، ۱۹ (۷۴) ۱۶۵ - ۱۸۳.
۷. قلی‌پور، س. ۱۳۹۱. بررسی سیاست‌های دولت در بازار گوجه‌فرنگی در ایران،

اقتصاد کشاورزی و توسعه - سال بیست و یکم، شماره ۸۳

مؤسسه مطالعات پژوهش و بازرگانی، باشگاه خبرنگاران جوان.

۸. قدیمی، م. و مشیری، س. ۱۳۸۱. مدل سازی و پیش بینی رشد اقتصادی در ایران با استفاده از شبکه های عصبی مصنوعی (ANN). *پژوهشهای اقتصادی ایران*، ۴ (۱۲): ۹۷-۱۲۵.

۹. گجراتی، د. ۱۹۹۵. مبانی اقتصاد سنجی. ترجمه حمید ابریشمی. انتشارات دانشگاه تهران.

۱۰. منهای، م. ب. ۱۳۷۷. مبانی شبکه های عصبی (هوش محاسباتی). نشر دکتر حسابی. دانشگاه تهران.

۱۱. نجفی، ب. زیبایی، م.، شیخی، م. ح. و طرازکار، م. ح. ۱۳۸۶. پیش بینی برخی محصولات زراعی در استان فارس: کاربرد شبکه عصبی مصنوعی. *مجله علوم و فنون کشاورزی و منابع طبیعی*، ۱۱(۱): ۵۰۱-۵۱۱.

۱۲. نوفرستی، م. ۱۳۷۴. آمار در اقتصاد و بازرگانی. تهران: انتشارات رسا.

13. Dillon, J.L., & Hardaker, J.B. 1993. Farm management research for small farmer development. Rome: FAO.

14. Forsgren, A. & Kling, R. 2003. Av implementation of recurrent, neural network for prediction and control of nonlinear dynamic system, Dissertation for PHD Degree. Faculty of IT at Mouash University. Melborn. Australia.

15. Gonzalez, S. 2000. Neural network for macroeconomic forecasting: a complementary approach to linear regression models, Working paper, 2000-07.

16. Haoffi, Z., Guoping, X., Fagting, Y. & Han, Y. 2007. A neural network model based on the multi-stage optimization approach for

short-term food price forecasting in china. *Expert System with Applications*, 33 : 347-356.

17.Haykin, S. 1994. Neural networks: a comprehensive foundation, Newyork: MacMillan.

18.Kohzadi, N., Boyd, M. S., Kastr, I., Kermanshahi, B. S. & Scuse, D. 1995. Neural networks for forecasting: an introduction. *Canadian Journal of Agricultural Economics*, 463-474.

19.Kumar, P. & Walia, E. 2006. Cash forecasting: an application of artificial neural networks in finance, *International Journal of Computer Science & Applications*, 61-77.

20.Medsker, L. R. & Jain, L. C. 2000. Recurrent neural networks : design and applications. Boca Raton, FL : CRC Press.

21.Moshiri, S., Cameron, N. & Scuse, D. 1999. Statics Dynamic, and hybrid neural networks in forecasting inflation. *Computational Economics*, 14: 219-235.

22.Racine, J. S. 2001. On the nonlinear predictability of stock returns using financial and economic variables, for the coming. *Journal of Business and Economic Statistics*, 19(3): 80-382.

23. Qaesemi, A., Asadpoor, H. and Shasadeghi, S. 2000. Using artificial neural networks time series forecasting and the results comparison with ARIMA Approach. *Iranian Journal of Trade Studies*, 7(14) 87-120.