اقتصادکشاورزی و توسعه، سال بیست و یکم، شماره ۸۳، پاییز ۱۳۹۲

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

ولی‌بریم‌نژاد*، ملیحه بکشلو**

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

چکیده

در این مطالعه کارایی روش ARIMA و شبکه عصبی خودرگرسیونی در پیش‌بینی قیمت خرده‌فروشی محصول گوجه فرنگی مقایسه شدند. داده‌های مورد استفاده شامل قیمتهای هفتگی خرده فروشی گوجه فرنگی طی سالهای ۱۳۸۸تا 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 پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی دارای خطای پایین‌تر است و در نتیجه کاراتر از ARIMA عمل می‌کند.

طبقه بندی JEL: C22 ، C45، C53، Q11

* دانشیار گروه اقتصاد کشاورزی، دانشگاه آزاد اسلامی، واحد کرج (نویسندهٔ مسئول)
e-mail: vali_borimnejad@kiau.ac.ir
** دانشجوی کارشناسی ارشد اقتصاد کشاورزی، دانشگاه آزاد اسلامی، واحد کرج

کلید واژه‌ها:

پیش‌بینی، قیمت، گوجه فرنگی، شبکهٔ عصبی خود رگرسیونی[1]، ARIMA

مقدمه

تولید در بخش کشاورزی با شوکهای تصادفی و پیش‌بینی ناپذیر ناشی از شرایط آب و هوایی، آفت و سایر بلایای طبیعی همچون آتش‌سوزی روبه‌روست. از طرفی این شوکها قیمت محصولات کشاورزی، عملکرد بخش کشاورزی و نیز رفاه مصرف‌کنندگان را به شدت تحت‌تأثیر 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 ماه های 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 (قلی پور، 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 بهینهٔ منابع، افزایش کارایی، افزایش مطلوبیت زراعان و در نهایت افزایش درآمد آنها می گردد؛ 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 زراعان کمک زیادی نیز به عوامل بازاریابی این بخش، به ویژه انبارداری، می کند 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 می کنند(Dillon & Hardaker, 1993).

1. Neural Network AutoRegressive Model

در این میان بررسی محصولاتی که دارای بیشترین نوسان هستند، ضروری‌تر می‌باشد. گوجه فرنگی 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 لازمهٔ 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، کهزادی و همکاران (Kohzadi et al., 1995) در مطالعه‌ای به پیش بینی قیمت گندم و گاو زنده با استفاده از شبکه های عصبی پیشخور و مدل ARIMA برای دوره زمانی ۱۹۹۰-۱۹۵۰ پرداختند و دریافتند خطای پیش بینی شبکه عصبی کمتر از مدل ARIMA است. در مطالعه‌ای دیگر، کومار و والیا (Kumar and Walia, 2006) برای بهینه‌سازی عرضهٔ پول نقد، تقاضای آن را با استفاده از مدلهای شبکهٔ 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 شبکهٔ عصبی مصنوعی عملکردی بهتر از روشهای سری زمانی دارد. همچنین قاسمی و همکاران (۲۰۰۰) به پیش بینی قیمت شیر با استفاده از شبکه‌های عصبی مصنوعی و مدل ARIMA پرداختند و دریافتند که خطای پیش بینی 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 براورد کرده و دو روش را مورد مقایسه قرار دادند. نتایج حاکی از آن است که شبکهٔ عصبی مصنوعی در تمام افقهای زمانی، دقیقتر از روش ARIMA عمل می‌کند. فهیمی فرد و همکاران (۱۳۹۰) به مقایسه توان پیش بینی مدل عصبی- فازیِ ANFIS با مدل شبکه عصبیِ ANN و خود رگرسیونیِ 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 پیش بینی قیمت تخم مرغ برخوردارند. فرج زاده و شاه ولی (۱۳۸۸) قیمت محصولات کشاورزی (پنبه و برنج و زعفران) را پیش بینی کردند. نتایج نشان داد بهترین پیش بینی 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 می دهد 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 – خودرگرسیونی به منظور انتخاب روشی است که کمترین خطا را در پیش بینی قیمت محصول گوجه فرنگی نشان می دهد.

مواد و روشها

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

می‌شوند. از جمله روشهای رگرسیون علی می‌توان به مدل خودرگرسیو با واریانس ناهمسان شرطی[1] 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 شبکهٔ عصبی معروف است. گفتنی است موفقیت شبکه های عصبی به عنوان ابزاری قدرتمند به منظور تجزیه وتحلیل داده‌ها، موجب شده است تا توجه اقتصاددانان به این روش پیش بینی جلب شود و در اواخر دهه ۸۰ میلادی مدلهای مختلفی جهت پیش‌بینی متغیرهای اقتصادی ساخته شود (فهیمی فرد و همکاران، ۱۳۹۰).

در بسیاری از مطالعات انجام شده، روش ARIMA بر دیگر روشهای خطی پیش بینی 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 اخلال 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:

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

که در آن Y_t، i، j، φ و θ به‌ترتیب 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 براورد 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 لایهٔ ورودی، پنهان و خروجی تشکیل شده است. لایهٔ ورودی فقط اطلاعات را دریافت می‌کند و مشابه متغیر مستقل عمل می‌نماید و لذا تعداد نرونهای لایهٔ ورودی بستگی به تعداد متغیرهای مستقل دارد. لایهٔ خروجی نیز همانند متغیر وابسته عمل کرده و تعداد نرونهای آن بستگی به تعداد متغیرهای وابسته دارد؛ اما بر خلاف لایه‌های ورودی و خروجی، لایهٔ پنهان هیچ مفهومی را نشان نمی‌دهد و صرفاً یک نتیجهٔ میانی در فرایند محاسبهٔ ارزش خروجی است (قدیمی و مشیری، ۱۳۸۱).

معمولاً در شبکه‌های عصبی، کل داده‌های در دسترس، به دو مجموعهٔ آموزشی[1] و مجموعه آزمایشی[2] طبقه‌بندی می‌شوند. مجموعهٔ آموزشی با الگوریتم یادگیری برای تخمین وزنهای شبکه به کار می‌رود و مجموعهٔ آزمایشی برای ارزیابی دقت پیش‌بینی شبکهٔ آموزش‌دیده 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

۲. شبکه‌های عصبی از انعطاف‌پذیری تابعی ساختار شبکه ناشی می‌شود. در شبکه‌های عصبی طیف گسترده‌ای از تکنیکهای آماری مانند رگرسیون خطی، مدل پروبیت 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)[1] دارد که با استفاده از این شبکه ها امکان دستیابی به مدلهای پرتر از هر دو نوع مدلهای خطی و شبکه های 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، اضافه‌کردن مدل AR به یک مدل شبکهٔ عصبی برای تشکیل شبکهٔ عصبی خود رگرسیونی(NNAR) به صورت زیر می باشد:

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

که در آن f یک نگاشت انجام گرفته بوسیله شبکه عصبی می‌باشد(Medsker & Jain, 2000) .

ورودی شبکهٔ عصبی، وقفه‌های مقادیر واقعی هدف[2] $y(t)$ می‌باشد و n_y مقادیر واقعی هدف است که توسط سیستم تعیین می‌شود. ساختار شبکه عصبی پویا چنین است:

شکل ۱. ساختار NNAR

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

1-Artificial Neural Network
2. Target

تـابع آمـوزش ایـن شـبکه Levenberg-Marquardt (LM)[1] و تـابع یـادگیری آن، GDM[2] می‌باشد و برای لایهٔ خروجی، تـابع فعـال سـازی خطـی بـه کـار رفـت. طراحـی بخـش خطـی (AR) این مدل توسط خود سیستم انجـام مـی‌گیـرد. در نهایـت، بـرای بررسـی کـارایی مـدل، داده‌های خروجی شبکه با دادهای واقعی مقایسه گردید. LM تابع آموزشـی اسـت کـه مقـادیر وزنهـا و اریبهـا را براسـاس روش بهینـه‌سـازی Levenberg-Marquardt بهنگـام مـی‌کنـد (Medsker & Jain, 2000). تابع کارایی خطای پیش فرض این شبکه، میـانگین مجـذور خطـا می‌باشد.

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

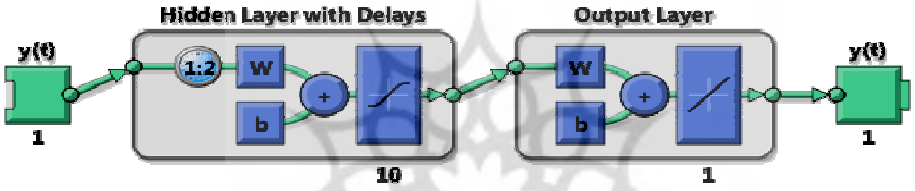

شکل ۲. مدل پویای شبکه عصبی خود رگرسیونی(NNAR)

در این مطالعه، در تمامی مدلها قیمت خـرده‌فروشـی گوجـه‌فرنگـی بـه عنـوان تـابعی از مقادیر گذشته آن مدل‌سازی شد. داده‌های به‌کار رفته در ایـن مطالعـه بـه صـورت کتابخانـه ای گردآوری شد. برای براورد مدل خطی از نرم‌افزار Eviews و برای حل مـدل شـبکهٔ عصـبی از نرم افزار MATLAB استفاده گردید.

بررسی قدرت پیش‌بینی

به منظور مقایسهٔ قدرت پیش‌بینی، از معیارهای مختلـف و از جملـه میـانگین قـدر مطلـق خطا[3]، میانگین مجذور خطا[1]، ریشه میانگین مربعات خطا[2] و شاخص درصد میانگین مطلق خطا[3] استفاده گردید. این معیارها را می‌توان به‌صورت روابط زیر نشان داد (Haykin, 1994):

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

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

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

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

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

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 داده های 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 عمدهٔداده‌ها (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 گوجه فرنگی

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 و۱+ (logisig) تبدیل می‌شود (Haoffi et al. , 2007). همچنین برای طراحی شبکه، از ساختارهای مختلف شبکهٔ انتشار برگشتی پیشخور با تابع آموزشی LM با تکرار ۱۰۰=Epoch ، 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

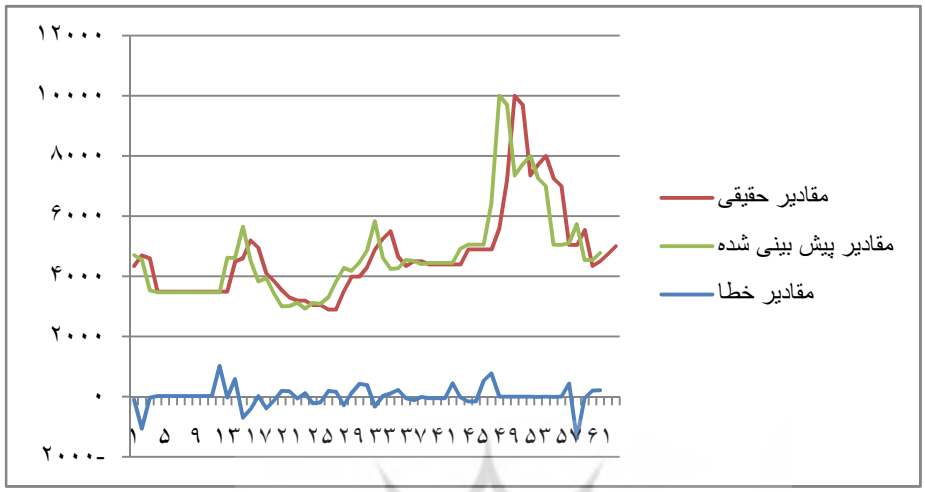

نمودار ۱. نتایج پیش‌بینی قیمت بااستفاده از فرایند NNAR و مقایسه آن مقادیر حقیقی

جدول ۱. بررسی کارایی مدل NNAR در پیش بینی قیمت خرده فروشی گوجه فرنگی

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

مأخذ: یافته‌های تحقیق

بررسی کارایی مدل ARIMA در پیش بینی قیمت خرده فروشی گوجه فرنگی

به منظور تعیین کارایی مدل ARIMA در پیش‌بینی سری زمانی مذکور، ابتدا ایستایی سری زمانی با آزمون دیکی فولر تعمیم یافته (ADF)[1] 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 آمارهٔ 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

سپس با استفاده از معیارهای AC و PAC به ترتیب بهترین مرتبه q و p 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(۱و۲و۱) ARIMA به عنوان بهترین حالت انتخاب شد.

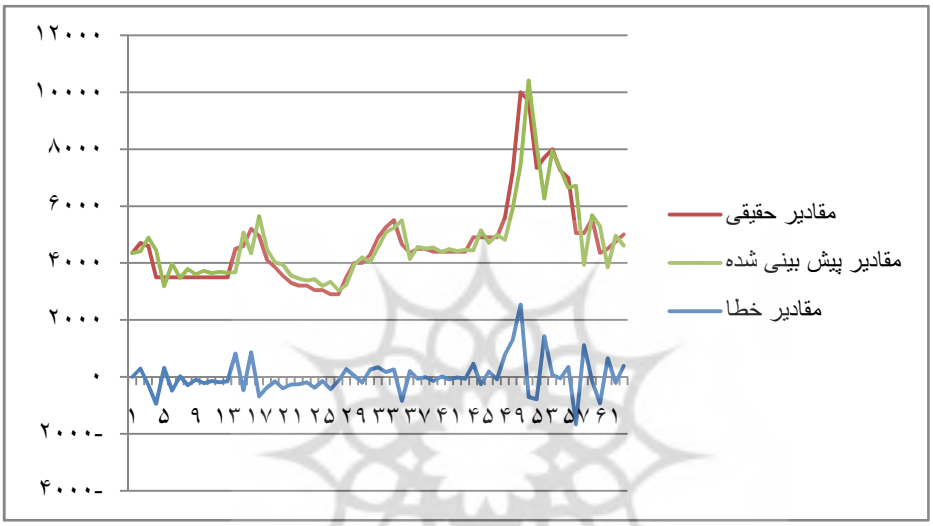

نمودار ۲. نتایج پیش بینی قیمت بااستفاده از فرایند ARIMA و مقایسه آن با مقادیر حقیقی

جدول ۲. بررسی کارایی مدل ARIMA در پیش‌بینی قیمت خرده فروشی گوجه فرنگی

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

مأخذ: یافته‌های تحقیق

شرط لازم برای کاراتر 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 مقایسهٔ 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 می کند.

این نتایج بایافته های 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 شبکهٔ 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 شبکهٔ عصبی خود رگرسیونی 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 درکنار سایر مدلهای متداول پیش‌بینی؛

۲. شبکه‌های عصبی با محدودیتهایی از جمله فقدان یک تئوری جامع روبه روست و از طرفی وزنهای 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 چغندرقند در ایران، *مجله چغندر قند*، شماره۲۵.

۳.خلیق، پ. و مقدسی،ر. ۱۳۸۷. پیش بینی قیمت محصول گوجه فرنگی به کمک الگوهای شبکه عصبی مصنوعی و سری زمانی. اولین کنگره ملی فناوری تولید و فرآوری گوجه فرنگی. 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.فرج زاده، ز.، شاه ولی، ا. ۱۳۸۸. پیش بینی قیمت محصولات کشاورزی مطالعه موردی پنبه و برنج و زعفران. *مجله اقتصاد کشاورزی و توسعه*، ۶۷: ۴۳-۷۱.

۶.فهیمی فرد، س.م.، سالارپور،م. و صبوحی،م. ۱۳۹۰. مقایسه توان پیش بینی 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.قلی پور، س. ۱۳۹۱. بررسی سیاست های دولت در بازار گوجه فرنگی در ایران،

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.منهاج، م.ب. ۱۳۷۷. مبانی شبکه‌های 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, JL., & 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., Kastra, 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.