

پیش بینی قیمت گوجه فرنگی: کاربرد روش تلفیقی شبکه عصبی _ خودرگرسیون

ولی بریم نژاد^۱ و ملیحه بکشلو^۲

چکیده

در این مطالعه پیش بینی قیمت خرده فروشی محصول گوجه فرنگی با استفاده از روش ARIMA و شبکه عصبی خودرگرسیونی^۳ مورد بررسی قرار گرفت. داده های مورد استفاده شامل قیمت های خرده فروشی گوجه فرنگی طی سال های ۱۳۸۹-۱۳۸۸ که به صورت هفتگی از سازمان میادین میوه و تره بار تهران گردآوری شد. به منظور مقایسه خطای پیش بینی از معیارهای میانگین مجذور خطا، میانگین قدر مطلق خطا و معیار درصد میانگین مطلق خطا استفاده شد. نتایج مطالعه نشان داد که مدل غیرخطی شبکه عصبی خودرگرسیونی NNAR در پیش بینی قیمت خرده فروشی گوجه فرنگی دارای خطای پایین تر بوده و در نتیجه کارتر از ARIMA عمل می کند.

طبقه بندی JEL: Q11, C53, C45, C32, C22

"واژه های کلیدی": "پیش بینی"، "قیمت"، "گوجه فرنگی"، "شبکه عصبی"

مقدمه

فرایند پیش بینی معمولاً شامل گرفتن اطلاعات گذشته و حال و تعمیم آن ها به آینده به کمک مدل های ریاضی است. از آنجا که پیشگویی وقایع آینده، در فرایند تصمیم گیری نقش عمده ای را ایفا می کند، لذا پیش بینی برای بسیاری از سازمان ها و نهادها حائز اهمیت است. گجراتی پیش بینی را بخش مهمی از تحلیل های اقتصادسنجی می داند، و برای برخی از محققان مهم ترین قسمت از علم اقتصادسنجی، پیش بینی است (گجراتی، ۱۹۹۵).

باتوجه به این که کشاورزان توانایی کنترل شرایط آب و هوایی، سازمان بازار و محیط نهادی که در آن تولید می کنند را ندارند، معمولاً با ریسک تولید و قیمت مواجهند. تولید در بخش کشاورزی با شوک های تصادفی و غیرقابل پیش بینی ناشی از شرایط آب و هوایی، آفت و سایر بلاهای طبیعی همچون آتش سوزی روبرو است. از طرفی قیمت محصولات کشاورزی، عملکرد بخش کشاورزی و نیز رفاه مصرف کنندگان را به شدت تحت تأثیر قرار می دهد. در نتیجه نوسان های قیمتی که محصولات کشاورزی در معرض آن قرار دارند، هم تولید کنندگان و هم مصرف کنندگان را تهدید می نماید. تغییر قیمت های کشاورزی، می تواند پیامدهای اقتصادی-اجتماعی گسترده ای داشته باشد. تأثیر فوری این تغییرات، متوجه مصرف مواد غذایی و تولید محصولات کشاورزی است. بر این اساس، بررسی نوسانات قیمتی محصولات کشاورزی و پیش بینی دقیق آن می تواند موجب انتخاب نوع محصول و سطح زیر کشت مناسب آن، باعث تخصیص بهینه منابع، افزایش کارایی، افزایش مطلوبیت زراعتی و در نهایت افزایش درآمد زراعتی

۱- ولی بریم نژاد، دانشیار، عضو هیئت علمی دانشگاه آزاد اسلامی، واحد کرج

۲- ملیحه بکشلو، دانشجوی کارشناسی ارشد اقتصاد کشاورزی دانشگاه آزاد اسلامی واحد کرج

می‌گردد. چرا که قیمت‌ها به طور کلی نقش راهنما را در جریان تولید و مصرف کالاها بر عهده دارند. پیش‌بینی قیمت محصولات کشاورزی علاوه بر کمک به درآمد زراعتین کمک زیادی نیز به عوامل بازاریابی این بخش بویژه 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، تدوین و اجرا می‌کنند (دیلون و هارداکر، ۱۹۹۳).

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، بویژه 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 اقتصاد سنجی 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 (راسین، ۲۰۰۱). 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 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 (کهنزادی "و همکاران"، ۱۹۹۵). در مطالعه‌ای دیگر، کومار و همکاران، برای بهینه‌سازی عرضهٔ پول نقد، اقدام به پیش‌بینی تقاضای آن، 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 دوم آوریل تا سی ام جون ۲۰۰۴ کردند. نتایج نشان داد که شبکهٔ عصبی مصنوعی عملکردی بهتر از روش‌های سری زمانی دارند (کومار و والیا، ۲۰۰۶). همچنین قاسمی و همکاران 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 (قاسمی "و همکاران"، ۲۰۰۰). مشیری و همکاران با هدف پیش‌بینی تورم در ایران، از مدل‌های ساختاری تورم، مدل‌های سری زمانی و شبکهٔ عصبی مصنوعی استفاده نمودند. نتایج، حاکی از آن بود که شبکه‌های عصبی در زمینهٔ پیش‌بینی تورم نسبت به سایر مدها عملکرد بهتری دارند (مشیری "و همکاران"، ۱۹۹۹). مرزبان و همکاران، پیش‌بینی نرخ ارز مدل شبکهٔ عصبی را با مدل‌های اقتصاد سنجی و سری زمانی مقایسه کرده‌اند. مدل‌های شبکهٔ عصبی نسبت به مدل‌های اقتصاد سنجی ساختاری و سری زمانی به وضوح دارای قدرت بیشتری بودند (مرزبان "و همکاران"، ۱۳۸۳). طیبی و همکاران 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 شبکهٔ عصبی مصنوعی در تمام افق‌های زمانی، دقیق‌تر از روش ARIMA عمل می‌کند (طیبی "و همکاران"، ۱۳۸۸).

روش تحقیق

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 تعدیل‌نمایی 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^۱ و از جمله روش‌های رگرسیون غیرعلی می‌توان به فرآیند ARIMA و ARMA اشاره نمود. اما امروزه روش جدیدتری نیز برای پیش‌بینی ابداع شده که به رویکرد شبکه عصبی معروف است.

الگوی خود رگرسیون میانگین متحرک (ARIMA)

به طور کلی، فرآیندی 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 آن را توسط فرآیند $ARMA(p, q)$ مدل‌سازی کنیم. در این صورت سری زمانی اصلی، سری زمانی خود رگرسیونی میانگین متحرک انباشته $ARIMA(p, d, q)$ است (گجراتی، ۱۹۹۵). فرآیند $ARIMA(p, d, q)$ ، برای متغیر X را می‌توان به صورت رابطه زیر نشان داد:

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

که در آن :

$$y_t = \Delta^d X_t = (1-L)^d X_t$$

و $f(t)$ روند زمانی را در صورت وجود در y_t برآورد می‌کند.

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. 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 بر خلاف 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^۲ و مجموعه آزمایشی^۳ طبقه‌بندی می‌شوند. مجموعه آموزشی با الگوریتم یادگیری برای تخمین وزن‌های شبکه استفاده می‌شود 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:

1- Auto Regressive Conditional Heteroscedasticity (ARCH)
2 - Training Set
3 - Testing Set

۱- با موفقیت می توان ارتباطات غیرخطی را مدل سازی کرد. در برخورد با ارتباطات غیرخطی، شبکه های عصبی با توابع محرک غیرخطی بهتر از مدل های رگرسیون خطی عمل می کنند.

۲- شبکه های عصبی، از انعطاف پذیری تابعی ساختار شبکه ناشی می شود. در شبکه های عصبی طیف گسترده ای از تکنیک های آماری مانند رگرسیون خطی، مدل پروبیت مضاعف، مدل های خود توضیحی و ... می توانند برای ایجاد اصلاحات در توابع محرک و ساختار شبکه (مانند تغییر نرون ها در هر لایه) مورد استفاده قرار گیرند.

شبکه های پویا دارای یک بخش خطی خودرگرسیون (AR) و یک بخش غیرخطی شبکه عصبی پیشخور انتشار برگشتی (ANN) ^۱ بوده که با استفاده از این شبکه ها امکان دستیابی به مدل هایی که بر هر دو نوع مدل های خطی و شبکه های عصبی انتشار برگشتی برتری داشته باشند وجود دارد (فرگوسن و کلینگ، ۲۰۰۳).


یکی از رهیافت هایی که برای ساخت مدل های پویای غیرخطی با استفاده از شبکه های عصبی بکار می رود، اضافه کردن مدل AR به یک مدل شبکه عصبی برای تشکیل شبکه عصبی خود رگرسیون (NNAR) به صورت زیر می باشد:

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

که در آن f یک نگاشت انجام گرفته بوسیله شبکه عصبی می باشد (مدسکر و جین، ۲۰۰۰).

ورودی شبکه عصبی، وقفه های مقادیر واقعی هدف $y(t)$ می باشد و n_y مقادیر واقعی هدف بوده که توسط سیستم تعیین می شوند.

ساختار شبکه عصبی پویا:



"نگاره (۱) ساختار NNAR"

نحوه آموزش در این نوع شبکه مبتنی بر قانون یادگیری اصلاح خطا است. در این روش، آموزش با مجموعه وزن های تصادفی اولیه، آغاز می شود (هایکین، ۱۹۹۴). تابع آموزش این شبکه، Levenberg-Marquardt (LM) ^۳ و تابع یادگیری آن، GDM ^۴ می باشد و برای لایه خروجی تابع فعال سازی خطی استفاده شد. 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 وزن ها و اریب ها را بر اساس روش بهینه سازی Levenberg-Marquardt به هنگام می کند (مدسکر و جین، ۲۰۰۰). تابع کارایی پیش فرض این شبکه، میانگین مجذور خطا می باشد.


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

1-Artificial Neural Network

2 - Target

3 -Levenberg, (1944) & Marquardt, (1963)

4 -Gradient Descent With Momentum Weight/bias Learning Function



"نگاره (۲) مدل پویای شبکه عصبی - خود رگرسیونی (NNAR)

در این مطالعه، در تمامی مدل‌ها قیمت خرده‌فروشی گوجه‌فرنگی به عنوان تابعی از مقادیر گذشته آن مدل‌سازی شد. داده‌های به‌کار رفته در این مطالعه داده‌های هفتگی قیمت خرده‌فروشی گوجه‌فرنگی مربوط به سال‌های ۱۳۸۹-۱۳۸۸ است که از سازمان میادین میوه و تره بار تهران گردآوری شد. برای حل مدل خطی از نرم‌افزار Eviews و برای حل مدل شبکه عصبی از نرم‌افزار MATLAB استفاده گردید.

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 (هائوفی و همکاران، ۲۰۰۷). در این مطالعه ۷۰٪ داده‌ها به آموزش و ۳۰٪ داده‌ها به آزمون خروجی مدل NNAR اختصاص داده شد.

بررسی قدرت پیش‌بینی

به منظور مقایسه قدرت پیش‌بینی، از معیارهای مختلف و از جمله میانگین قدر مطلق خطا^۱، میانگین مجذور خطا^۲، ریشه میانگین مربعات خطا^۳ و شاخص درصد میانگین مطلق خطا^۴ استفاده گردید. این معیارها را می‌توان بصورت روابط زیر نشان داد:

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

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

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


در این روابط n تعداد پیش‌بینی، e_i خطای پیش‌بینی nام است که از تفاوت مقادیر پیش‌بینی شده و مقادیر واقعی به دست می‌آید.

-
- 1 - Mean Absolute Error
 - 2 - Mean of Square Error
 - 3 - Root Mean Square Error
 - 4 - Mean Absolute Percentage Error

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 داده‌های سری زمانی با استفاده از روش هایکین به اعداد بین ۰ و ۱+ (logsig) تبدیل می‌کند که نرمال می‌شود (هائوفی "و همکاران"، ۲۰۰۷). همچنین برای طراحی شبکه، از ساختارهای مختلف شبکه انتشار برگشتی پیشخور با تابع آموزشی LM با تکرار $\text{Epoch}=100$ ، 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.



"نگاره (۳) پیش‌بینی قیمت با استفاده از فرایند NNAR"

"جدول (۱) بررسی کارایی مدل NNAR در پیش‌بینی قیمت خرده‌فروشی گوجه فرنگی"

MAPE	MAE	RMSE	معیار خطا
۴/۸۸۵	۲۰۸/۰۲۶	۳۵۳/۱۱۸	مقدار

"مأخذ: یافته‌های تحقیق"

بررسی کارایی مدل ARIMA در پیش‌بینی قیمت خرده‌فروشی گوجه فرنگی به منظور کارایی مدل ARIMA در پیش‌بینی سری زمانی مذکور، ابتدا ایستایی سری زمانی با آزمون دیکسی فولر تعمیم یافته (ADF) مورد بررسی قرار گرفت. جدول زیر خلاصه‌ای از نتایج را نشان می‌دهد:

"جدول (۲) نتایج آزمون ایستایی سری قیمت گوجه فرنگی"

احتمال	آماره t	
۰/۰۰۰	-۴/۲۵۳۱۸۹	آماره دیکی فولر تعمیم یافته
	-۳/۵۴۲۰۹۷	%۱
	-۲/۹۱۰۰۱۹	%۵
	-۲/۵۹۲۶۴۵	%۱۰

مقادیر آزمون بحرانی

متغیر وابسته: $D(Y,2)$

"مأخذ: یافته‌های تحقیق"


جدول شماره ۲ نشان می‌دهد که درجه ایستایی (d) برای سری زمانی مورد بررسی برابر دو می‌باشد، یعنی سری زمانی بعد از دو مرتبه تفاضل گیری 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 سه سطح اطمینان ایستا شده است.

سپس با استفاده از معیارهای AC و PAC به ترتیب بهترین مرتبه q و p را مشخص می‌کنیم و می‌دانیم که حدهای اعتماد تقریبی (فاصله اطمینان) ۹۵٪ بین ۰/۲۰۸۹ و ۰/۲۰۸۹- می‌باشند (گجراتی، ۱۹۹۵). لذا جهت پیش‌بینی قیمت گوجه‌فرنگی فرایند (۱و۲) ARIMA به عنوان بهترین حالت انتخاب شد. نتایج برآورد مدل ARIMA در جدول شماره ۳ آمده است:

"جدول (۳) نتایج برآورد مدل ARIMA"

متغیر	ضرایب	انحراف معیار	آماره t	احتمال
C	۴۷۵۹/۰۸۴	۵۸۰/۴۳۸۳	۸/۱۹۹۱۲۲	۰/۰۰۰۰
AR(1)	۰/۷۷۴۶۶۵	۰/۰۸۷۴۱۰	۸/۸۶۲۳۸۲	۰/۰۰۰۰
MA(1)	۰/۶۲۹۰۷۶	۰/۱۰۸۰۶۰	۵/۸۲۱۵۳۹	۰/۰۰۰۰

"مأخذ: یافته‌های تحقیق"



"نگاره (۴) پیش‌بینی قیمت با استفاده از فرایند ARIMA"

"جدول (۴) بررسی کارایی مدل ARIMA در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی"

MAPE	MAE	RMSE	معیار خطا
۷/۹۵	۴۰۱/۰۵	۶۱۳/۱۷	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 شماره ۵، نتایج حاصل از مقایسه کارایی مدل‌های مذکور در پیش‌بینی قیمت گوجه‌فرنگی ارائه شده است.

"جدول (۵) مقایسه کارایی مدل‌ها در پیش‌بینی قیمت گوجه‌فرنگی"

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

"مأخذ: یافته‌های تحقیق"

کمیت حاصل از تقسیم MAE, RMSE مدل NNAR بر مدل ARIMA کوچکتر از یک بوده و به ترتیب برابر ۰/۵۷۶ و ۰/۵۱۹ می‌باشد. بنابراین مدل NNAR در مقایسه با مدل ARIMA، داده‌های واقعی را با خطای کم‌تری شبیه‌سازی می‌کند. در نتیجه مدل NNAR بر مدل ARIMA در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی برتری دارد. که این نتایج با نتایج خلیق و مقدسی (۱۳۸۷) مطابقت داشت. آن‌ها در یک مطالعه، قیمت گوجه‌فرنگی را با استفاده از مدل شبکه‌های 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. همچنین با نتایج اثنی عشری (۱۳۸۶) نیز منطبق بود. وی در مطالعه‌ای به بررسی تأثیر سیاست‌های پولی و مالی بر اشتغال بخش کشاورزی و پیش‌بینی میزان اشتغال با استفاده از روش‌های شبکه‌های عصبی و خودرگرسیون برداری پرداخت. نتایج مطالعه وی نشان داد که مدل شبکه‌های عصبی، در پیش‌بینی اشتغال از عملکرد بهتری برخوردار است.

نتیجه‌گیری و پیشنهادات

گرچه روش ARIMA به عنوان رایج‌ترین روش خطی پیش‌بینی، نقشی اساسی ایفا می‌نماید، ولی نتایج مطالعه نشان داد روش شبکه‌های عصبی مصنوعی، ابزار قدرتمندی در پیش‌بینی قیمت بوده و چون در آن آموزش را تکرار می‌کنیم، در به حداقل رساندن خطای پیش‌بینی تواناست. 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.

۲. شبکه‌های عصبی با محدودیت‌هایی از جمله فقدان یک تئوری جامع روبروست و از طرفی وزن‌های شبکه‌های عصبی مانند ضرایب مدل‌های رگرسیون، قابل تفسیر نیست. بنابراین پیشنهاد می‌شود این شبکه‌ها برای پیش‌بینی استفاده شوند نه برای تحلیل‌های سیاستی.

منابع

- اثنی عشری. ه (۱۳۸۶) تأثیر سیاست‌های پولی و مالی بر اشتغال بخش کشاورزی ایران، پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه زابل.
- جهرمی، م. ح. محمدی و ز. فرج‌زاده (۱۳۸۶) پیش‌بینی قیمت چغندر قند در ایران، *مجله چغندر قند*، شماره ۲۵.
- خلیق. پ و ر. مقدسی (۱۳۸۷) پیش‌بینی قیمت محصول گوجه فرنگی به کمک الگوهای شبکه عصبی مصنوعی و سری زمانی، اولین کنگره ملی فناوری تولید و فرآوری گوجه فرنگی.
- طیپی. س. ک. ک. آذربایجانی و ل. بیاری (۱۳۸۸) مقایسه مدل‌های شبکه عصبی مصنوعی و سری‌های زمانی برای پیش‌بینی قیمت گوشت مرغ در ایران، *پژوهشنامه علوم اقتصادی*، شماره ۱.
- قدیمی. م و س. مشیری (۱۳۸۱) مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی، *فصلنامه پژوهش‌های اقتصادی ایران*، شماره ۱۲.
- گجراتی. د (۱۹۹۵) مبانی اقتصاد سنجی، ترجمه: ح. ابریشمی، انتشارات دانشگاه تهران.
- مرزبان. ح. ر. اکبریان و ب. جواهری (۱۳۸۳) یک مقایسه بین مدل‌های اقتصادسنجی ساختاری، سری زمانی و شبکه عصبی برای پیش‌بینی نرخ ارز، *مجله تحقیقات اقتصادی*، شماره ۱۲.
- منه‌ج. م. ب (۱۳۷۷) مبانی شبکه‌های عصبی (هوش محاسباتی)، نشر دکتر حسابی، دانشگاه تهران.
- ۸-نوفروستی. م (۱۳۷۴) آمار در اقتصاد و بازرگانی، انتشارات رسا، تهران.
- 9-Dillon JL. and JB. Hardaker (1993) Farm management research for small farmer development, FAO, Rome.
- 10-Forsgren A. and R. Kling (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.
- Ghasemi E. H. Asadpour and M. Shasadeqi (2000) An Application of Neural Network in Time Series Forecast and its Comparison with ARIMA Model, *Iranian Journal of Trade Studies(IJTS) Quarterly*, No: 14, PP. 87-120. (Inpersian)
- Gonzalez S (2000) Neural Network for macroeconomic forecasting: A complementary approach to linear regression models, Working paper, 2000-07.
- Haoffi Z. Guoping. X. Fagting. Y and Y. Han (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.
- Haykin s (1994) *Neural Networks : A Comprehensive Foundation*. Macmillan, Newyork.
- Kohzadi N. Boyd. M. S. Kastr. I. Kermanshahi. B. S and D. Scuse (1995) Neural Networks for Forecasting:An introduction, *Canadian Journal of Agricultural Economics*, 463-474.
- Kohzadi N. Boyd. M. S. Kermanshahi. B and L. Kaastra (1996) A Comparison of Artificial Neural Networks And Time series Model For Forecasting Commodity Prices, *Neurocomputing*, 10: 169-181.
- Kumar P. and E. Walia (2006) Cash Forecasting An Application of Artificial Neural Networks in Finance, *International Journal of Computer Science & Applications*, 61-77.
- Medsker L. R and L. c. Jain (2000) *Recurrent Neural Networks : Design and Applications*, Boca Raton, FL : CRC Press.
- Moshiri s. Cameron. N and D. Scuse (1999) Statics Dynamic, and Hybrid Neural Networks in Forecasting Inflation, *Computational Economics*, 14: 219-235.
- 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.



Forecasting the price of tomatoes: using combined neural network auto-regressive approach

Vali Borimnejad¹ & Maliheh Bakeshlou²

Abstract

In this study, we anticipated the retail price of tomato using ARIMA and neural network auto-regressive model. The data used were weekly that, included the retail prices of tomatoes during 1389-1388 and gathered from Tehran Fruits and Vegetables Organization. In order to compare the predictions error, we used the mean square error, mean absolute error and mean absolute percent error criteria. The results showed that non-linear neural network auto-regressive model, in predicting the retail price of tomatoes has a lower error and thus is more efficient than ARIMA.

JEL Classification: C22,C32,C45,C53,Q11

"Key words": "forecasting", "price", "tomato", "neural network"

1- Vali Borimnejad, Associate Professor, Islamic Azad University, Karaj Branch

2- Maliheh Bakeshlou, Graduate Student of Islamic Azad University, Karaj Branch
vali.borimnejad@gmail.com